



VYSOKÁ ŠKOLA BÁŇSKÁ – TECHNICKÁ UNIVERZITA OSTRAVA  
EKONOMICKÁ FAKULTA

KATEDRA FINANCÍ

Predikce finančních časových řad podniku  
Forecasting of Corporate Financial Time Series

Student: Bc. Jan Kubečka

Vedoucí bakalářské práce: doc. Ing. Aleš Kresta, Ph.D.

Ostrava 2019

# Zadání diplomové práce

Student:

**Bc. Jan Kubečka**

Studijní program:

N6202 Hospodářská politika a správa

Studijní obor:

6202T010 Finance

Téma:

Predikce finančních časových řad podniku  
Forecasting of Corporate Financial Time Series

Jazyk vypracování:

čeština

Zásady pro vypracování:

1. Úvod
2. Popis metodiky predikce časových řad
3. Popis metodiky měření přesnosti predikce
4. Ověření a porovnání přesnosti zvolených metod predikce
5. Závěr

Seznam použité literatury

Seznam zkratk

Prohlášení o využití výsledků diplomové práce

Seznam příloh

Přílohy

Seznam doporučené odborné literatury:

BREALEY, R. A., S. C. MYERS and F. ALLEN. *Principles of corporate finance*. 11th global ed. Maidenhead: McGraw-Hill, 2014. ISBN 978-0-07-715156-0.

CIPRA, Tomáš. *Finanční ekonometrie*. 2. upr. vyd. Praha: Ekopress, 2013. ISBN 978-80-86929-93-4.

ZMEŠKAL, Z., D. DLUHOŠOVÁ a T. TICHÝ. *Finanční modely: koncepty, metody, aplikace*. 3. přeprac. a rozšíř. vyd. Praha: Ekopress, 2013. ISBN 978-80-86929-91-0.


Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.


Vedoucí diplomové práce: **doc. Ing. Aleš Kresta, Ph.D.**

Datum zadání: 23.11.2018

Datum odevzdání: 26.04.2019



  
Ing. Iveta Ratmanová, Ph.D.  
vedoucí katedry

  
prof. Dr. Ing. Zdeněk Zmeškal  
děkan fakulty

Prohlašuji, že jsem celou práci vypracoval samostatně.

V Ostravě dne 26.04.2019.



.....  
Bc. Jan Kubečka

Děkuji doc. Ing. Aleši Krestovi, Ph.D za odborné vedení, cenné rady a věcné připomínky při tvorbě mé diplomové práce.

## Obsah

<b>1 Úvod .....</b>	<b>4</b>
<b>2 Popis metodiky predikce časových řad .....</b>	<b>6</b>
2.1 Vícerozměrný lineární regresní model .....	6
2.1.1 Odhad metodou nejmenších čtverců .....	6
2.1.2 Využití regresního modelu k predikci .....	7
2.2 Interpolace, Extrapolace .....	8
2.3 Dekompozice časové řady .....	10
2.3.1 Metoda klouzavých průměrů .....	12
2.3.2 Exponenciální vyrovňávání .....	14
2.3.3 Dekompoziční postupy .....	15
2.4 Fuzzy přístup .....	17
<b>3 Popis metodiky měření přesnosti predikce .....</b>	<b>20</b>
3.1 Metody pro zjištění kvality regresních modelů .....	20
3.1.1 Ověření předpokladů regresního modelu .....	21
3.2 Metody stanovení přesnosti predikce dekompozičních modelů .....	23
<b>4 Ověření a porovnání zvolených metod .....</b>	<b>26</b>
4.1 Regresní model .....	26
4.1.1 Regresní modely zkrácených období .....	31
4.2 Model interpolace a „vyhlazování“ .....	33
4.3 Modely dekompozice časové řady .....	36
4.3.1 Kombinace sezónního faktoru a modelu interpolace .....	36
4.3.2 Metoda exponenciálního vyrovňávání .....	39
4.4 LFL Forecaster .....	41
4.5 Jednoduchá predikce průměrem .....	44
4.6 Porovnání výsledků jednotlivých metod .....	44
<b>5 Závěr .....</b>	<b>50</b>
<b>Seznam použité literatury .....</b>	<b>52</b>
<b>Seznam zkratk .....</b>	<b>53</b>
<b>Prohlášení o využití výsledků diplomové práce</b>	
<b>Seznam příloh</b>	
<b>Přílohy</b>	

# 1 Úvod

Predikce finančních časových řad jsou důležitou součástí řízení firmy. Na základě predikcí se stanovují finanční plány a budoucí strategie, od kterých se pak odvíjí úspěšný či neúspěšný chod podniku. Kvalitní predikční modely jsou tak důležitým nástrojem k dosažení podnikových cílů.

Cílem diplomové práce je nalézt vhodné modely pro stanovení odhadu vývoje finančních časových řad podniku. Vybranou časovou řadou jsou hodnoty tržeb za období mezi lety 2010 až 2017, přičemž data za rok 2018 slouží k porovnání predikovaných a reálných hodnot.

Vybraný podnik sídlí v České republice a je dceřinou společností polské firmy, která patří mezi hlavní dodavatele hliníkových slitin v rámci polského automobilového průmyslu. Hlavní úlohou vybrané dceřiné společnosti je zajistit dostatečné dodávky materiálu pro mateřskou společnost, od kterých se pak odvíjí výše zisku dceřiné společnosti.

Práce je rozdělená do pěti kapitol, přičemž první kapitolou je úvod a pátou kapitolou je závěr. V rámci druhé kapitoly jsou popsány jednotlivé metody pro stanovení predikovaných hodnot. Konkrétními vybranými metodami jsou regresní modely, modely na bázi dekompozice časové řady, model tzv. „vyhlazování“ pomocí funkce a model založený na teorii Fuzzy množin.

Ve třetí kapitole jsou popsány jednotlivé postupy pro ověření přesnosti a vypovídací hodnoty jednotlivých modelů, například ukazatel střední chyby odhadu nebo přesnosti směru vývoje, a také metody pro vzájemné srovnání vybraných modelů. Dále jsou také popsány postupy pro ověření předpokladů regresních modelů, tedy testy homoskedasticity, multikolinearity, normality reziduí či statistické významnosti.

Nejdůležitější částí práce je pak čtvrtá kapitola, ve které jsou odhadnuty vybrané modely dle vybraných časových řad. Na základě těchto modelů jsou predikovány hodnoty tržeb pro období od ledna do října roku 2018.

Hodnoty predikce dle jednotlivých metod jsou zaznamenány v příslušných grafech a tabulkách a stručně okomentovány. Tyto výsledky jsou dále vzájemně porovnávány pomocí metod popsanych v kapitole třetí, a to jak v rámci jednotlivých modelů, tak s reálnými hodnotami.

V závěru jsou shrnuty veškeré výsledky a obsah práce. Dále jsou vybrány modely

vhodné pro predikci finančních časových řad zvolené firmy, vzájemně porovnány dle vybraných kritérií a okomentovány vybrané poznatky.



## 2 Popis metodiky predikce časových řad

V této kapitole jsou popsány metody, na základě kterých bude provedena predikce vybraných finančních časových řad podniku. Metody jsou rozděleny do samostatných podkapitol, v rámci kterých jsou popsány jednotlivé kroky pro každou z metod. Při zpracování této kapitoly byly využity informace z odborných publikací Arlt a Arltová (2009), Cipra (2013), Gouriéroux a Jasiak (2001), Hančlová (2012) a Zmeškal a kol. (2013).

### 2.1 Vícerozměrný lineární regresní model

Tato metoda vychází z předpokladu, že vysvětlovaná (někdy také označována jako závislá) proměnná  $Y$  je v čase ovlivněna různými faktory  $X_1, X_2, X_3, \dots, X_k$ . Vzájemný vztah mezi závislou a vysvětlujícími (nezávislými) proměnnými lze formulovat vícerozměrným lineárním regresním modelem ve tvaru:

$$Y_t = \beta_1 + \beta_2 \cdot X_{t2} + \beta_3 \cdot X_{t3} + \dots + \beta_k \cdot X_{tk} + u_t, \quad t = 1, 2, \dots, n, \quad (2.1)$$

kde  $Y_t$  je hodnota vysvětlované proměnné v čase  $t$ ,  $\beta_1$  je úroňová konstanta,  $\beta_2, \beta_3, \dots, \beta_k$  jsou parciální regresní koeficienty a  $u_t$  je reziduální odchylka. Regresní koeficienty  $\beta_k$  vyjadřují změnu střední hodnoty vysvětlované proměnné  $Y$  při zvýšení proměnné  $X_k$  o jednu jednotku za podmínek ceteris paribus, tedy při předpokladu, že ostatní nezávislé proměnné zůstanou fixní.

Pro potřeby modelu je tedy nejprve nutné vybrat závislou (vysvětlovanou) proměnnou a vysvětlující proměnné. Dále je vhodné stanovit předpoklady chování regresních koeficientů, tedy jaký vliv bude mít jednotková změna proměnné  $X_k$  na změnu hodnoty závislé proměnné. Po stanovení předpokladů lze reálnou závislost mezi proměnnými odhadnout na základě bodového diagramu, kde na ose  $Y$  jsou zaznamenány hodnoty závislé proměnné a na ose  $X$  jsou zaznamenány hodnoty jedné z nezávislých proměnných  $X_k$ .

#### 2.1.1 Odhad metodou nejmenších čtverců

Pro odhad jednotlivých parametrů vícerozměrného regresního modelu lze využít různých metod, nicméně pro účely této práce byla vybrána metoda nejmenších čtverců, která vychází z myšlenky minimalizace součtu čtverců reziduální složky.

Postup minimalizace lze zapsat ve tvaru optimalizační úlohy:

$$RSS = \hat{u}' \cdot \hat{u} = (y - X \cdot \hat{\beta})' \cdot (y - X \cdot \hat{\beta}) \rightarrow MIN. \quad (2.2)$$

Podmínkou pro řešení optimalizační úlohy je dle Hančlová (2012):

$$\frac{\partial \hat{u}' \cdot \hat{u}}{\partial \hat{\beta}} = -2X'y + 2X'X\hat{\beta}, \quad (2.3)$$

a řešení pro regresní koeficienty je tedy:

$$\hat{\beta} = (X' \cdot X)^{-1} \cdot yX'. \quad (2.4)$$

Při použití metody nejmenších čtverců je také nutné splnit předpoklady, které jsou dle Hančlová (2012) následující:

**P1:** Lineární regresní model  $Y_t = \beta_1 + \beta_2 \cdot X_i + u_i,$  (2.5)

je lineární v parametrech.

**P2:** Matice  $X$  není stochastická. (2.6)

Tento předpoklad je vždy splněn, pokud se modeluje na základě výběrových dat a znamená, že výběrový soubor má pevně stanovené proměnné  $X_1, X_2, X_3, \dots, X_k$ .

**P3:**  $var(u_i/X_i) = E(u_i - E(u_i/X_i))^2 = \sigma^2.$  (2.7)

Tato podmínka vyjadřuje, že pro každou  $i$  – tou skupinu náhodné složky bude rozptýl stejný, tedy tzv. předpoklad homoskedasticity reziduí.

**P4:**  $cov(u_i; u_j/X_i; X_j) = E\{(u_i/X_i) \cdot (u_j/X_j)\} = 0 \text{ pro } i \neq j.$  (2.8)

Tato podmínka vyjadřuje, že náhodná složka z různých skupin není sériově závislá, tedy tzv. autokorelaci reziduí.

**P5:** Normální rozdělení reziduí  $u_i \sim N(0; \sigma^2).$  (2.9)

**P6:** Hodnost matice  $X$  se rovná součtu sloupců a ten je menší nebo roven počtu řádků matice, tedy:  $h(X) = k \leq n.$  (2.10)

Tento předpoklad vyvrací problém multikolinearity nezávislých proměnných.

Jednotlivé metody pro ověření předpokladů pro vybrané regresní modely budou popsány v rámci třetí kapitoly.

## 2.1.2 Využití regresního modelu k predikci

Predikce se provádí na bázi intervalového odhadu střední a individuální hodnoty. Pro potřeby odhadu uvažujeme vícerozměrný regresní model dle vzorce (2.1) a tedy

bodová predikce pro období  $t = 0$  vychází z matice  $X$  dle:

$$x'_0 = [1 \ X_{02} \ \dots \ X_{0k}], \quad (2.11)$$

„potom lze odhadnout bodovou predikci střední hodnoty  $Y_0$ :

$$E(Y_0/x'_0) = x'_0 \cdot \hat{\beta}. \quad (2.12)$$

Bodová predikce ve vztahu (2.12) nemusí být totožná se skutečnou hodnotou  $E(Y_0)$ . Z těchto důvodů odhadneme rozptyl predikované střední hodnoty:

$$\widehat{\sigma^2}_{(Y_0/x'_0)} = \widehat{\sigma^2}_{\hat{u}} \cdot x'_0 \cdot (X' \cdot X)^{-1} \cdot x_0 \quad (2.13)$$

a sestavíme  $(1 - \alpha)$  % konfidenční interval  $E(Y_0/x'_0)$ , tj. provedeme intervalovou predikci střední hodnoty predikované veličiny:

$$\begin{aligned} \hat{Y}_0 - t_{1-\frac{\alpha}{2}} \cdot \sigma^2_{(Y_0/x'_0)} \cdot \sqrt{x'_0(X'X)^{-1}x_0} &\leq E(Y_0/x'_0) \leq \\ &\leq \hat{Y}_0 + t_{1-\alpha/2} \cdot \sigma^2_{(Y_0/x'_0)} \cdot \sqrt{x'_0(X'X)^{-1}x_0}. \end{aligned} \quad (2.14)$$

Obdobným způsobem postupujeme i pro predikci individuální hodnoty  $Y_0$  – stanovíme chybu predikce a konstruujeme  $(1 - \alpha)$  % interval spolehlivosti. Rozptyl chyby predikce individuální hodnoty  $Y_0$  lze vyjádřit:

$$\widehat{\sigma^2}_{(Y_0/x'_0)} = \widehat{\sigma^2}_{\hat{u}} \cdot (1 + x'_0 \cdot (X' \cdot X)^{-1} \cdot x_0) \quad (2.15)$$

a potom  $(1 - \alpha)$  % intervalová predikce individuální hodnoty  $Y_0$  je dána

$$\hat{Y}_0 - t_{1-\frac{\alpha}{2}} \cdot \sigma^2_{(Y_0/x'_0)} \leq E(Y_0/x'_0) \leq \hat{Y}_0 + t_{1-\alpha/2} \cdot \sigma^2_{(Y_0/x'_0)}. \quad (2.16)$$


V současné době je již celá řada softwarových ekonometrických produktů, které generují bodové i intervalové predikce vysvětlované proměnné pro požadovanou úroveň významnosti a při očekávaných hodnotách prediktorů.“ (Hančlová, 2012, s. 89)

## 2.2 Interpolace, Extrapolace


Principem této metody je nalézt vhodnou funkci, která by popisovala vývoj hodnot zvolené časové řady. Lze obecně říci, že pro danou časovou řadu lze najít křivku, která by procházela přímo, nebo alespoň velmi blízko hodnotám této řady. Tato křivka může být pak konstruována pomocí interpolace, tedy spojováním sousedních hodnot časové řady přímkami (viz obr. 2.1). Následně lze tyto přímky pomocí tzv. „vyhlazování“ spojit v jednu křivku, která zároveň bude grafem funkce (viz obr. 2.2). Danou funkci můžeme

dále tzv. „protáhnout“, tedy pomocí extrapolace (obr. 2.3) stanovit hodnoty za krajními body intervalu známých hodnot.


Obr. 2.1: Mechanismus interpolace



Obr. 2.2: Mechanismus vyhlazování



Obr. 2.3: Mechanismus Extrapolace



Uvažujme, že pomocí interpolace a následného vyhlazování bylo stanoveno, že výše tržeb je lineární funkcí času, tedy že tržby v čase lineárně buď rostou, nebo klesají. Funkční závislost tržeb na čase můžeme zapsat např. ve tvaru:

$$tržby_t = 2 + 4t, \text{ pro } t = 0, 1, \dots, n, \quad (2.17)$$

a můžeme tedy dle vzorce 2.17 odhadnout hodnotu tržeb pro námi zvolený časový úsek. Pro účely této práce je k nalezení vhodné funkce pro popis časové řady využít software SPSS.

## 2.3 Dekompozice časové řady

Jak tvrdí Cipra (2013), některé časové řady, a především ty ekonomického charakteru, mohou být rozloženy na několik specifických složek, kterými jsou trend, sezónnost, cyklická složka a reziduální složka. Rozklad časové řady na tyto složky (tzv. dekompozice), je prováděna s nadějí, že se v jednotlivých složkách rozložené časové řady dá lépe rozpoznat pravidelné chování časové řady než je tomu u nerozložené řady.

*„Trend odráží dlouhodobé změny v průměrném chování časové řady resp. Obecnou tendenci vývoje zkoumaného jevu za dlouhé období. Je výsledkem faktorů, které dlouhodobě působí ve stejném směru jako je např. technologie výroby, demografické podmínky či podmínky trhu v dané oblasti. Trend může mít různý charakter, může být rostoucí, klesající, strmý, mírný, v průběhu času se může měnit, takže jej lze pokládat spíše za cyklus. Může být hladší než je vlastní časová řada, nebo také variabilnější.“* (Arlt a Arltová, 2009, s. 13)

*„Sezónní složka popisuje periodické změny v časové řadě, které se odehrávají během jednoho kalendářního roku a každý rok se opakují. Sezónní změny jsou způsobeny střídáním ročních dob a s ním souvisejících lidských zvyků, které jsou institucionálně zakotveny v ekonomické aktivitě (např. nezaměstnanost, nehodovost na silnicích, produkce mléka, prodej spotřebního zboží a související čerpání prostředků z platebních karet během roku). Pro analýzu sezónní složky jsou vhodná především měsíční nebo čtvrtletní data, neboť při řidších pozorováních nelze obvykle sezónní složku identifikovat (figuruje zde termín Nyquistova frekvence, což velmi zjednodušeně řečeno pro ekonomické řady znamená, že identifikace sezónnosti je zde možná, jen když jsou pozorování alespoň pololetní). Sezónní složka často mění rok*

od roku svůj charakter (např. s globálním oteplováním mizí zimní propady ve stavebních ukazatelích). Eliminace sezónní složky se v praxi obvykle označuje jako sezónní očišťování a statistické úřady (EU, USA i jinde) mají obvykle povinnost publikovat časové řady v sezónně očištěné podobě. Proto je sezónnosti v ekonometrii a financích věnována velká pozornost včetně účinného softwaru. Často se např. využívá metodika označovaná jako Census X11 a Census X12 původně vyvinutá v americkém U.S. Bureau of Census (viz např. EViews).

Cyklická složka je nejspornější složkou časové řady. Někteří autori se vyhýbají nazvat tuto složku cyklickou (nebo dokonce periodickou) a hovoří spíše o fluktuacích kolem trendu, v nich se střídá fáze růstu a fáze poklesu. Délka jednotlivých cyklů (tj. vzdálenost mezi dvěma sousedními horními nebo dolními body zvratu) je obvykle proměnlivá a stejně tak může být proměnlivá intenzita jednotlivých fází cyklického průběhu. Cyklická složka může být důsledkem evidentních vnějších vlivů, někdy je ale určení jejich příčin velmi obtížné. Typickým představitelem této složky je tzv. obchodní cyklus (business cycle), který představuje střídání recese a konjunktury v ekonomických aktivitách – jeho délka se obvykle pohybuje v rozmezí od 5 do 7 let. Eliminace cyklické složky nebývá jednoduchá jak z věcných důvodů, neboť je obtížné nalézt příčiny jejího vzniku, tak z výpočetních důvodů, protože charakter této složky se může podobně jako u sezónní složky v čase měnit. Někdy se sezónní a cyklický složka označují souhrnně jako periodické složky časové řady.

Reziduální složka (označována podobně jako v regresním modelu také náhodná či iregurní) zbývá v časové řadě po odstranění trendu a sezónní i cyklické složky. Je tvořena náhodnými pohyby (fluktuacemi) v průběhu časové řady, které nemají (rozpoznatelný) systematický charakter. Proto se již nezapočítává mezi předchozí, tzv. systematické složky časové řady. Reziduální složka pokrývá rovněž chyby v měření dat a některé chyby (např. zaokrouhlování), kterých se dopouští analytik při vlastní analýze řady. Aby byly odůvodněny některé statistické postupy, které se s časovou řadou při klasické dekompozici provádějí, předpokládá se obvykle, že reziduální složka je tzv. bílý šum (někdy dokonce normální bílý šum, tj. bílý šum s normálním rozdělením).“ (Cipra, 2013, s. 232-233)

Časovou řadu si tak můžeme představit jako trend, ke kterému jsou dále připojeny cyklická, sezónní a reziduální složka. Časová řada pak může být rozložena dle aditivní dekompozice ve tvaru:

$$y_t = Tr_t + C_t + Sz_t + E_t, \quad (2.18)$$

kde  $y_t$  je hodnota veličiny v čase  $t$ ,  $Tr_t$  je trendová složka v čase  $t$ ,  $C_t$  je cyklická složka v čase,  $Sz_t$  je sezónní složka v čase a  $E_t$  je reziduální složka v čase.

Další možností je dekompozice de multiplikativní vazby, tedy ve tvaru:

$$y_t = Tr_t \cdot C_t \cdot Sz_t \cdot E_t. \quad (2.19)$$

Pro stanovení trendové složky, jsou v rámci práce využity metody a postupy, které jsou dále popsány dle metodiky Cipra (2013).

### 2.3.1 Metoda klouzavých průměrů

Tuto metodu lze zařadit mezi tzv. adaptivní přístupy k systematické složce. „Adaptivní přístupy lze obecně charakterizovat tak, že jsou schopny pracovat se systematickými složkami (např. trendem), které mění v čase svůj globální charakter, takže speciálně pro ně např. nelze použít žádnou matematickou křivku s neměnnými parametry. Na druhé straně se však předpokládá, že v krátkých úsecích časové řady je takové vyrovnaní pomocí matematických křivek možné, i když tyto křivky mají obvykle v různých úsecích odlišné parametry. Je tedy možné pouze lokální vyrovnavání (či eliminace) trendu. Např. tedy nelze vyrovnat časovou řadu pomocí přímky

$$\beta_0 + \beta_1 \tau, \tau = 1, \dots, n, \quad (2.20)$$

ale pro krátké úseky se středy v jednotlivých časových bodech  $t$  lze použít vyrovnaní pomocí lokálních trendů

$$\beta_0(t) + \beta_1(t)\tau, \tau = \dots, t-1, t, t+1, \dots. \quad (2.21)$$

Proces eliminace trendové složky se tedy přizpůsobuje (adaptuje) okamžitému lokálnímu průběhu řady, přičemž dokonce stupeň tohoto přizpůsobení lze vědomě řídit. Další výhodou adaptivních metod je konstrukce předpovědí pružně reagujících na časové změny v charakteru řady a výpočetní jednoduchost.“ (Cipra, 2013, s. 274-275)

Pod názvem klouzavých průměrů označujeme lineární kombinace členů původní řady s jednotkovým součtem vah, např. typu:

$$\frac{1}{8}(y_{t-2} + 2y_{t-1} + 2y_t + 2y_{t+1} + y_{t+2}). \quad (2.22)$$

„V praxi se často používají další typy klouzavých průměrů. Vůbec nejjednoduššími jsou tzv. jednoduché klouzavé průměry, což jsou běžné aritmetické průměry. Např. jednoduchý klouzavý průměr délky 5 je

$$\bar{y}_t^{(5)} = \frac{1}{5}(y_{t-2} + y_{t-1} + y_t + y_{t+1} + y_{t+2}). \quad (2.23)$$

*Jednoduchý klouzavý průměr délky  $2m + 1$*

$$\bar{y}_t^{(2m+1)} = \frac{1}{2m+1}(y_{t-2} + y_{t-1} + y_t + y_{t+1} + y_{t+2}), \quad (2.24)$$

*odpovídá klouzavému průměru z odstavce 9.2.1 s řádem 0 nebo 1 a toutéž délkou  $2m + 1$  (tj. odpovídá vyrovnaní úseku řady o délce  $2m + 1$  konstantním nebo lineárním trendem). Proto je také speciálně pro jednoduchý klouzavý průměr délky 5 při použití řádu 0*

$$\bar{y}_n^{(5)} = \frac{1}{5}(y_{n-4} + y_{n-3} \dots + y_n), \quad (2.25)$$

*(pro libovolné  $\tau > 0$ ) nebo při použití řádu 1*

$$\bar{y}_{n-1}^{(5)} = \frac{1}{10}(y_{n-3} + 2y_{n-2} + 3y_{n-1} + 4y_n),$$

$$\bar{y}_n^{(5)} = \frac{1}{5}(-y_{n-4} + y_{n-2} + 2y_{n-1} + 3y_n),$$

$$\hat{y}_{n+1}(n) = \frac{1}{10}(-4y_{n-4} + y_{n-3} + 2y_{n-2} + 5y_{n-1} + 8y_n), \dots \quad (2.26)$$

*Jiným typem jsou centrované klouzavé součty, které reagují na potřebu vyrovňovat ekonomické časové řady průměrováním přes jednotlivé sezóny (tj. např. pro čtvrtletní řady používat klouzavé průměry délky 4 a pro měsíční řady klouzavé průměry délky 12). Klouzavé průměry sudých délek však způsobují problém, jakým časovým bodům takové průměry přiřazovat: např. jednoduchý klouzavý průměr lednové až prosincové hodnoty měsíční časové řady spadá doprostřed mezi časové body „červen“ a „červenec“. Jestliže však dále zprůměrujeme dva takové sousední jednoduché klouzavé průměry odpovídající středu intervalu „červen-červenec“ a „červenec-srpen“, pak výslednou hodnotu lze bez obav přiřadit časovému bodu „červenec“. Jinými slovy, vytváříme klouzavé průměry typu*

$$\begin{aligned} \bar{y}_t^{(12)} &= \frac{1}{2} \left( \frac{1}{12}(y_{t-6} + y_{t-5} \dots + y_t + y_{t+5}) + \frac{1}{12}(y_{t-5} + y_{t-4} \dots + y_t + y_{t+6}) \right) = \\ &= \frac{1}{24}(y_{t-6} + 2y_{t-5} + 2y_{t-4} + \dots + 2y_{t+5} + y_{t+6}), \end{aligned} \quad (2.27)$$

*o délce 13. Tedy např. pro výpočet vyrovnané červencové hodnoty použijeme únorovou až prosincovou hodnotu příslušného roku (všechny s váhami  $1/12$ ) a lednovou hodnotu uvažovaného a následujícího roku (obě s váhami  $1/24$ ). Obecně lze psát*



$$\bar{y}_t^{(2m)} = \frac{1}{4m} (y_{t-m} + 2y_{t-m+1} + \dots + y_{t+m-1} + y_{t+m}), \quad (2.28)$$

a mluví se pak o centrováných klouzavých průměrech (čtvrtletních  $\bar{y}_t^{(4)}$  pro  $m=2$  či měsíčních  $\bar{y}_t^{(12)}$  pro  $m=6$ ).“ (Cipra, 2013, s. 285-286)

### 2.3.2 Exponenciální vyrovnávání

„Exponenciální vyrovnávání je dalším adaptivním přístupem k trendové složce, který se v praxi často používá. Vyrovnaná hodnota je zde zvláštním případem klouzavého průměru, kdy všechny dosud pozorované hodnoty vyrovnávané řady vážíme do minulosti exponenciálně klesajícími váhami. Vyrovnaná řada  $\hat{y}_t$  přitom minimalizuje výrazy typu

$$(y_t - \hat{y}_t)^2 + (y_{t-1} - \hat{y}_{t-1})^2 \beta + (y_{t-2} - \hat{y}_{t-2})^2 \beta^2 + \dots, \quad (2.37)$$

kde  $\beta$  ( $0 < \beta < 1$ ) je předem zvolená diskontní konstanta. V součtu (2.37) tedy dochází k jakémusi diskontování vah, které je rozumně odůvodnitelné: pozorováním vzdálenějším do minulosti přiřazuje stále nižší váhy. I když popsany princip exponenciálního vyrovnávání se může zdát na první pohled složitý, je po vlastní výpočetní stránce velmi jednoduchý, pokud se používají rekurentní vzorce.“ (Cipra, 2013, s. 288)

#### 2.3.2.1 Jednoduché exponenciální vyrovnávání

„Jednoduché exponenciální vyrovnávání používáme pro řady, u kterých lze trend považovat za lokálně (tedy v krátkých úsecích řady) konstantní

$$Tr_t = \beta_0. \quad (2.38)$$

Úkolem je nyní nalézt odhad parametru  $\beta_0$ . Protože se však jedná o adaptivní přístup k vyrovnávání řady, bude tento odhad záviset na časovém okamžiku, v němž byl proveden. Označme  $b_0(t)$  odhad parametru  $\beta_0$  provedený v čase  $t$ , tj. zkonstruovaný na základě pozorování  $y_t, y_{t-1}, y_{t-2}, \dots$ , která v čase  $t$  máme k dispozici. Odhad  $b_0(t)$  pak bude představovat jednak odhadnutou hodnotu trendu v čase  $t$  a zároveň vyrovnanou hodnotu  $\hat{y}_t$  uvažované řady. Získáme jej vzhledem k (2.37) minimalizací výrazu

$$\sum_{j=0}^{\infty} (y_{t-j} - \beta_0)^2 \beta_j, \quad (2.39)$$

kde  $\beta$  ( $0 < \beta < 1$ ) je předem zvolená diskontní konstanta. Je nutné upozornit na to, že výraz (2.39) má tvar nekonečného součtu, přestože v praktických situacích známe vždy jen konečný počet hodnot  $y_1, \dots, y_n$ . Hypotetické prodloužení řady do minulosti však podstatně zjednoduší příslušné vzorce, protože odpovídá limitním přechodům v těchto vzorcích. Navíc výpočetní postup vyplývající z této abstrakce využívá pouze známé hodnoty  $y_1, \dots, y_n$  uvažované řady.“ (Cipra, 2013, s. 288-289)

### 2.3.2.2 Dvojitě exponenciální vyrovnávání

„Dvojitě exponenciální vyrovnávání (označované také někdy jako Brownova metoda) používáme pro řady, u kterých lze trend považovat za lokálně (tedy v krátkých úsecích řady) lineární

$$Tr_{t-j} = \beta_0 + \beta_1 \cdot (-j). \quad (2.40)$$

Odhady parametrů  $\beta_0$  a  $\beta_1$  v čase  $t$  označované jako  $b_0(t)$  a  $b_1(t)$  získáme minimalizací výrazu

$$\sum_{j=0}^{\infty} [y_{t-j} - (\beta_0 + \beta_1 \cdot (-j))]^2 \beta_j, \quad (2.41)$$

kde opět  $\beta$  ( $0 < \beta < 1$ ) je předem zvolená diskontní konstanta.“ (Cipra, 2013, s. 292-293)

Vyrovnanou hodnotu stanovenou dle Brownovy metody pak můžeme zapsat ve tvaru:

$$\hat{y}_t = 2Y_{t-1} - Y_{t-2} - 2(1 - \alpha)\epsilon_{t-1} + [(1 - \alpha)^2]\epsilon_{t-2}, \quad (2.42)$$

kde  $\alpha$  je vyrovnávací konstanta a  $\epsilon_t$  je chyba odhadu v čase  $t$ .

### 2.3.3 Dekompoziční postupy

Pro stanovení sezónního faktoru je nejprve nutné stanovit normalizační pravidlo pro aditivní vazbu:

$$I_{1+12i} + I_{2+12i} + \dots + I_{12+12i} = 0, \quad (2.29)$$

a pro multiplikativní vazbu:

$$I_{1+12i} \cdot I_{2+12i} \cdot \dots \cdot I_{12+12i} = 1. \quad (2.30)$$

#### Aditivní dekompozice

„Zkonstruují se centrované klouzavé průměry  $\bar{y}_t^{(12)}$  (při čtvrtletních pozorováních by se konstruovaly centrované klouzavé průměry  $\bar{y}_t^{(4)}$ ); jako vyrovnané počáteční a

koncové hodnoty řady lze např. zopakovat první a poslední spočitatelný centrovaný klouzavý průměr (při menším počtu pozorování).

Zkonstruované klouzavé průměry lze považovat za hrubý odhad trendové složky, který nám umožní řadu „trendově očistit“

$$y_t^* = y_t - \bar{y}_t^{(12)}. \quad (2.31)$$

Odhadneme (necentrované) sezónní faktory  $I_1^*, I_2^*, \dots, I_{12}^*$ : přitom (necentrovaný) sezónní faktor  $I_j^*$  pro  $j$ -tý měsíc v roce odhadneme jako aritmetický průměr všech těch hodnot  $y_t^*$ , které odpovídají  $j$ -tému měsíci v roce ( $j = 1, \dots, 12$ ).

Provedeme centrování hodnot  $I_1^*, I_2^*, \dots, I_{12}^*$  odečtením jejich aritmetického průměru

$$I_j = I_j^* - \bar{I}^* = \frac{I_1^* + \dots + I_{12}^*}{12}, \quad j = 1, \dots, 12, \quad (2.32)$$

aby bylo splněno normalizační pravidlo (2.29)

Provedeme konečné sezónní očištění řady do tvaru

$$\hat{y}_t^{(12)} = y_t - I_j, \quad (2.33)$$

kde  $t$  odpovídá  $j$ -tému měsíci v roce.

### **Multiplikativní dekompozice**

Zkonstruují se centrované klouzavé průměry  $\bar{y}_t^{(12)}$  stejně jako při aditivní dekompozici.

Provedeme „trendové očištění“ dané řady

$$y_t^* = \frac{y_t}{\bar{y}_t^{(12)}}. \quad (2.34)$$

Odhadneme (necentrované) sezónní faktory  $I_1^*, I_2^*, \dots, I_{12}^*$ : přitom (necentrovaný) sezónní faktor  $I_j^*$  pro  $j$ -tý měsíc v roce odhadneme jako aritmetický průměr všech těch hodnot  $y_t^*$ , které odpovídají  $j$ -tému měsíci v roce ( $j = 1, \dots, 12$ ).

Provedeme centrování hodnot  $I_1^*, I_2^*, \dots, I_{12}^*$  vydělením jejich geometrickým průměrem

$$I_j = \frac{I_j^*}{\bar{I}^*} = \frac{I_j^*}{\sqrt[12]{I_1^* \dots I_{12}^*}}, \quad j = 1, \dots, 12, \quad (2.35)$$

aby bylo splněno normalizační pravidlo (2.30)

Provedeme konečné sezónní očištění řady do tvaru

$$\hat{y}_t^{(12)} = \frac{y_t}{I_j}, \quad (2.36)$$

kde  $t$  odpovídá  $j$ -tému měsíci v roce.“ (Cipra, 2013, s. 300-301)

## 2.4 Fuzzy přístup

„Fuzzy množina je obecně zobrazení  $n$ -rozměrného prostoru do intervalu  $[0;1]$  nebo  $(0;1]$ . Toto zobrazení se nazývá funkce příslušnosti a označuje se  $\tilde{s} \equiv \mu_{\tilde{s}}(x)$ . Typů fuzzy množin je celá řada. Mezi aplikačně nejrozšířenější patří tzv. fuzzy čísla, někdy se hovoří o fuzzy intervalech.

Fuzzy číslo je fuzzy množina, která je definována na reálných číslech a splňuje předpoklad normality, což znamená, že alespoň jedna hodnota funkce příslušnosti je rovna 1, konvexnosti,  $\varepsilon$ -řezy jsou kompaktní podmnožiny (intervaly), a spojitosti, tedy funkce příslušnosti je spojitá.

Typickým příkladem fuzzy čísla je tzv. trapezoidal (lichoběžníkové) číslo, označované jako  $T$ -číslo, někdy se hovoří také o  $L$ - $R$  číslu.

$T$ -číslo, které se označuje  $\tilde{s} \equiv (s^L, s^U, s^\alpha, s^\beta)$ , je definováno takto

$$\tilde{s} \equiv \mu_{\tilde{s}}(x) = \begin{cases} L(x) & \text{pro } s^L - s^\alpha < x < s^L \\ 1 & \text{pro } s^L \leq x \leq s^U \\ R(x) & \text{pro } s^U < x < s^U + s^\beta \\ 0 & \text{jinak,} \end{cases} \quad (2.43)$$

kde

$$L(x) = L \left[ \frac{x - (s^L - s^\alpha)}{s^\alpha} \right], \quad (2.44)$$

je reálná neklesající spojitá funkce a

$$R(x) = R \left[ \frac{(s^U - s^\beta) - x}{s^\beta} \right], \quad (2.45)$$

je reálná nerostoucí spojitá funkce.“ (Zmeškal, 2013, str. 214)

V rámci této práce byl pro stanovení hodnot predikce využit software LFL Forecaster<sup>1</sup>, který dle Dvořáčková a kol. (2018) při hledání trendové složky časové řady kombinuje tzv. fuzzy transformace (F-transformace) s fuzzy logikou.

---

<sup>1</sup> Demo verze dostupná zde: [http://irafm.osu.cz/en/c110\\_lfl-forecaster/](http://irafm.osu.cz/en/c110_lfl-forecaster/)

„Základní myšlenka F-transformace jako aproximační techniky spočívá v nahrazení spojitě funkce její diskrétní reprezentací použitím přímé F-transformace. Poté je tato diskrétní reprezentace transformována zpět do prostoru spojitých funkcí použitím inverzní F-transformace.“ (Pavliska, 2009, s. 13)

Pavliska (2009, s 21-22) dále tvrdí: „Předpokládejme, že máme danou spojitou funkci  $f$ , jejímž definičním oborem je  $d$ -rozměrná oblast  $D(f) = \Omega \subseteq R^d$ , pro kterou máme dán fuzzy rozklad  $P$  o  $k$  fuzzy množinách  $\tilde{A}_1, \dots, \tilde{A}_k$ . Potom máme:

- **(Integrální) F-transformace** funkce  $f(X)$  vzhledem k rozkladu  $P$  je  $k$ -tice reálných čísel  $FP = [F_1, \dots, F_k]$  vypočtených pomocí:

$$F_i = \frac{\int_{\Omega} f(X) A_i(X) dx}{\int_{\Omega} A_i(X) dx} \quad \text{pro } i = 1, \dots, k \quad (2.46)$$

- **Diskrétní F-transformace** funkce  $f(X)$  vzhledem k rozkladu  $P$  je  $k$ -tice reálných čísel  $FP = [F_1, \dots, F_k]$  vypočtených pomocí:

$$F_i = \frac{\sum_{j=1}^N f(X_j) A_i(X_j)}{\sum_{j=1}^N A_i(X_j)} \quad \text{pro } i = 1, \dots, k \quad (2.47)$$

- **Inverzní F-transformace**

$$f_{P,F}^{(-1)}(X) = \sum_{i=1}^k F_i A_i(X). \quad (2.48)$$

V rámci fuzzy logiky jsou využívána tzv. fuzzy IF-THEN pravidla, jenž můžeme dle Pavliska (2009) zapsat jako soustavu ve tvaru:

$$\begin{array}{lllll} R_1: & \text{IF } X \text{ is } A_1 & \text{THEN } Y \text{ is } B_1 \\ & \vdots & & \vdots & \\ & \vdots & & \vdots & \\ R_m & \text{IF } X \text{ is } A_m & \text{THEN } Y \text{ is } B_m \end{array} \quad (2.49)$$

která je jazykový popisem, kde každé  $A_i$ , resp.  $B_i$  je jazykový výraz představující symbolický název příslušející k odpovídajícím fuzzy množinám  $\tilde{A}_i$ , resp.  $\tilde{B}_i$ . Každé pravidlo  $R_i$  takového jazykového popisu (2.49) je pak lokálním popisem chování funkce  $\tilde{f}$  na oblasti pokryté odpovídajícími fuzzy množinami.

Uvažujme tedy, že zvolená časová řada je diskrétní funkcí  $x$  času  $t$  potom  $F_n[x] = [X_1, \dots, X_n]$  je fuzzy transformace funkce  $x$  vzhledem k fuzzy rozkladu. Inverzní F-transformace pak slouží jako model trendové složky časové řady.

V rámci diplomové práce je použit pro modelování na bázi fuzzy množin software

LFL Forecaster. Popis metodiky použité v rámci softwaru lze nalézt v manuálu<sup>2</sup> k LFL Forecaster.

---

<sup>2</sup> [http://irafm.osu.cz/f/SW/LFLF\\_documentation.pdf](http://irafm.osu.cz/f/SW/LFLF_documentation.pdf)

### 3 Popis metodiky měření přesnosti predikce

V rámci této kapitoly jsou popsány metody, které byly použity pro zjištění kvality jednotlivých predikčních modelů. Kapitola zahrnuje popis metod pro ověření předpokladů a statistické významnosti regresních modelů a popis metodiky pro stanovení přesnosti predikčních modelů založených na dekompozici časové řady.

#### 3.1 Metody pro zjištění kvality regresních modelů

Prvním důležitým krokem při sestavování regresního modelu je zjištění statistické významnosti modelu, kterou lze určit pomocí koeficientu determinance  $R^2$ , který vypočítáme dle vzorce:

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} = \frac{\hat{u}' \cdot \hat{u}}{y'y - n\bar{Y}^2}. \quad (3.1)$$

Hodnotu koeficientu lze následně využít pro stanovení hodnoty testové statistiky, která se pak následně porovnává s kritickou hodnotou pro zvolenou hladinu významnosti  $\alpha$  dle vztahu:

$$F_{vyp} = \frac{n-k}{k-1} \cdot \frac{R^2}{1-R^2} > F_{1-\alpha}(k-1, n-k), \quad (3.2)$$

kde  $k$  je počet vysvětlujících proměnných a  $n$  počet pozorování. Pokud platí podmínka, že hodnota  $F_{vyp}$  vyšší, než kritická hodnota pro zvolenou hladinu významnosti  $\alpha$ , tak lze přijmout hypotézu, že daný model je statisticky významný.

Podobně se pak postupuje při testování statistické významnosti jednotlivých vysvětlujících proměnných. Hodnota testové statistiky pro danou proměnnou se určí na základě vzorce:

$$t_{vyp} = \frac{\hat{\beta}_i}{\hat{\sigma}_{\hat{\beta}_i}}, \quad (3.3)$$

kde  $\hat{\beta}_i$  je hodnota regresního koeficientu  $i$  – té vysvětlující proměnné a  $\hat{\sigma}_{\hat{\beta}_i}$  je směrodatná odchylka hodnoty regresního koeficientu  $i$  – té nezávislé proměnné. Výsledná hodnota testové statistiky se dále porovnává s kritickou hodnotou pro zvolenou hladinu významnosti dle:

$$|t_{vyp}| > t_{1-\alpha/2, df}, \quad (3.4)$$

kde opět platí pravidlo, že pokud je hodnota testové statistiky větší, než kritická hodnota, tak lze přijmout hypotézu o statistické významnosti jednotlivých vysvětlujících

proměnných na zvolené hladině  $\alpha$ .

### 3.1.1 Ověření předpokladů regresního modelu

Po zjištění statistické významnosti modelu a jednotlivých vysvětlujících proměnných obvykle následuje ověření předpokladů, které byly stanoveny v podkapitole 2.1.1.

Pro ověření předpokladu normality reziduí, je vhodné využít různých grafických aparátů, jako je např. histogram četností proložený Gaussovou křivkou normálního rozdělení, nebo PP a QQ ploty. Pokud však z grafů nelze jednoznačně rozhodnout o normalitě náhodné složky, je vhodné využít Jarque-Bera testu. Testová statistika pro tento test se stanoví jako:

$$JB = n \cdot \left[ \frac{S^2}{6} + \frac{(K-3)^2}{24} \right], \quad (3.5)$$

kde  $S$  je koeficient šikmosti,  $K$  koeficient špičatosti souboru reziduí a  $n$  počet pozorování.

Poté následuje porovnání výsledku testové statistiky a kritické hodnoty. Pokud na zvolené hladině významnosti je hodnota testového kritéria nižší, než kritická hodnota, tak nelze zamítnout hypotézu o normálním rozdělení náhodné složky. Podmínku pro splnění předpokladu normality reziduí lze tedy zapsat jako:

$$JB < \chi^2_{1-\alpha, df}. \quad (3.6)$$

Dalším z předpokladů je homoskedasticita náhodné složky. Opět lze tento předpoklad testovat pomocí grafických nástrojů, kdy je vhodné použít graf vývoje druhé mocniny hodnoty standardizovaných reziduí v závislosti na jednotlivých nezávislých proměnných. Nicméně pro jasný a přesný výsledek je vhodnější použít např. Whiteův obecný test, který vychází z předpokladu, že původní regresní model rozšíříme o nové vysvětlující proměnné, kterými jsou druhé mocniny původních nezávislých proměnných a dále součiny dvojic jednotlivých vysvětlujících proměnných. Následně lze sestavit regresní model závislosti druhé mocniny nestandardizovaných reziduí na původní části regresního modelu a přidaných nových vysvětlujících proměnných, a to ve tvaru:

$$\begin{aligned} \hat{u}_t^2 = & \lambda_1 + \lambda_2 \chi_{t2} + \lambda_3 \chi_{t3} + \lambda_4 \chi_{t4} + \lambda_5 \chi_{t2}^2 + \lambda_6 \chi_{t3}^2 + \lambda_7 \chi_{t4}^2 + \lambda_8 \chi_{t2} \chi_{t3} + \lambda_9 \chi_{t2} \chi_{t4} + \\ & + \lambda_{10} \chi_{t4} \chi_{t3} + \epsilon_t. \end{aligned} \quad (3.7)$$

Následně se porovnává testová statistika s kritickou hodnotou dle vzorce:



$$nR_u^2 < \chi_{1-\alpha,df}^2. \quad (3.8)$$


kde  $n$  je počet pozorování,  $R_u^2$  je koeficient determinance regresního modelu pro druhou mocninu hodnoty nestandardizovaných reziduí a  $\chi_{1-\alpha,df}^2$  je kritická hodnota pro zvolenou hladinu významnosti a příslušné stupně volnosti. Pokud tedy platí pravidlo z rovnice (3.8) nelze zamítnout hypotézu, že rezidua nemají konstantní a konečný rozptyl.

Rezidua také musí splňovat předpoklad, že nejsou závislá na svých zpožděných hodnotách, tedy že v modelu není přítomna autokorelace. Vhodnou metodou pro ověření autokorelace je Durbin-Watsonův test, kde testovou statistiku, která se chová podle  $d$  rozdělení můžeme zapsat jako:

$$DW = \frac{\sum_{t=2}^n (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^n \hat{u}_t^2} \sim d_{n,k}. \quad (3.9)$$

Hodnota statistiky Durbin-Watsonova testu pak náleží intervalu jednomu z intervalů, které lze vidět v grafu 3.1, a podle kterých se pak rozhoduje o přítomnosti autokorelace.

Graf 3.1: Intervaly pro rozhodování o přítomnosti autokorelace



Zdroj: <https://eldum.phil.muni.cz/mod/book/view.php?id=1527&chapterid=210>

Posledním testovaným předpokladem je tzv. multikolinearita, tedy silná korelace mezi vysvětlujícími proměnnými. Vhodnou metodou pro zjištění multikolinearity v modelu je použití koeficientu VIF. Pro potřeby stanovení hodnoty koeficientu VIF je nejprve nutné odhadnout regresní model, který popisuje závislosti mezi jednotlivými vysvětlujícími proměnnými. Tento model můžeme zapsat ve tvaru:

$$X_{i,t} = \alpha_{i1} + \alpha_{i2}X_{t,2} + \dots \alpha_{i,i-1}X_{t,i-1} + \alpha_{i,i+1}X_{t,i+1} + \dots \alpha_{ik}X_{t,k} + \epsilon_{it}. \quad (3.10)$$

Výsledný model (3.10) pak má koeficient determinance, který můžeme označit jako  $R_{Xi}^2$ .

Koeficient VIF pro  $i$  – tý faktor pak lze vypočítat dle vzorce:

$$VIF_i = \frac{1}{1-R_{Xi}^2}. \quad (3.8)$$

Přičemž pro rozhodnutí o přítomnosti multikolinearity modelu platí, že pokud hodnota koeficientu VIF je větší než deset, pak je mezi vysvětlujícími proměnnými silná korelace.

### 3.2 Metody stanovení přesnosti predikce dekompozičních modelů

*„Míry, které se nejčastěji používají pro ocenění kvality zkonstruovaných předpovědí, posuzují souhrnně vývoj předpovědí v čase. Uvedeme nejčastěji používané míry tohoto typu v jednoduché situaci, kdy souhrnně posuzujeme přesnost předpovědí  $\hat{y}_{n+1}, \dots, \hat{y}_{n+h}$ , hodnot  $y_{n+1}, \dots, y_{n+h}$  (je úplně jedno, zda se jedná o multipředpověď či posloupnost předpovědí o jeden krok dopředu, statické či dynamické předpovědi apod.):*

(1) Součet čtvercových chyb SSE (sum of squared erros):

$$SSE = \sum_{t=n+1}^{n+h} (y_t - \hat{y}_t)^2 = \sum_{t=n+1}^{n+h} \varepsilon_t^2. \quad (3.9)$$

*je analogií kritéria nejmenších čtverců v regresních modelech.*

(2) Střední čtvercová chyba MSE (mean squared error):

$$MSE = \frac{1}{h} \sum_{t=n+1}^{n+h} (y_t - \hat{y}_t)^2 = \frac{1}{h} \sum_{t=n+1}^{n+h} \varepsilon_t^2. \quad (3.10)$$

*je často používanou kvadratickou ztrátovou funkcí. Některé softwarové systémy (např. EViews) navíc provádějí rozklad chyby MSE na tři složky*

$$\frac{1}{h} \sum_{t=n+1}^{n+h} (y_t - \hat{y}_t)^2 = (\bar{\hat{y}} - \bar{y})^2 + (s_{\hat{y}} - s_y)^2 + 2(1 - r_{\hat{y}y})s_{\hat{y}}s_y, \quad (3.11)$$

*( $\bar{\hat{y}}$ ,  $\bar{y}$ ,  $s_{\hat{y}}$ ,  $s_y$ , jsou příslušné výběrové průměry a (vychýlené) výběrové směrodatné odchylky hodnoty  $\hat{y}$  a  $y$ ;  $r_{\hat{y}y}$  je výběrový korelační koeficient mezi  $\hat{y}$  a  $y$ ), přičemž výstupem je*

- proporční vychýlení: 
$$\frac{(\bar{\hat{y}} - \bar{y})^2}{\frac{1}{h} \sum_{t=n+1}^{n+h} (y_t - \hat{y}_t)^2}, \quad (3.12)$$

- *proporční rozptyl*:

$$\frac{(s_{\hat{y}} - s_y)^2}{\frac{1}{h} \sum_{t=n+1}^{n+h} (y_t - \hat{y}_t)^2}, \quad (3.13)$$

- *proporční kovariance*:

$$\frac{2(1 - r_{\hat{y}y})s_{\hat{y}}s_y}{\frac{1}{h} \sum_{t=n+1}^{n+h} (y_t - \hat{y}_t)^2}, \quad (3.14)$$

tyto *proporční složky* mají zřejmě jednotkový součet, v němž *proporční vychýlení* udává, jak daleko je průměr předpovědí od průměru předpovídaných hodnot, *proporční rozptyl* udává, jak daleko je rozptyl předpovědí od rozptylu předpovídaných hodnot, a *proporční kovariance* pokrývá zbývající nesystematickou část předpovědní chyby (u „dobré“ předpovědní techniky jsou *proporční vychýlení* a *rozptyl* relativně malé a výrazně zde převládá *nesystematická složka*).

(3) *Odmocninová střední čtvercová chyba RMSE (root mean squared error)*:

$$RMSE = \sqrt{\frac{1}{h} \sum_{t=n+1}^{n+h} (y_t - \hat{y}_t)^2} = \sqrt{\frac{1}{h} \sum_{t=n+1}^{n+h} \varepsilon_t^2}, \quad (3.15)$$

vzniká *modifikací MSE*, aby byla měřena ve stejných jednotkách jako daná řada.

(4) *Střední absolutní chyba odhadu MAE (mean absolute error)*:

$$MAE = \frac{1}{h} \sum_{t=n+1}^{n+h} |y_t - \hat{y}_t| = \frac{1}{h} \sum_{t=n+1}^{n+h} |\varepsilon_t|. \quad (3.16)$$

Nepenalizuje tak výrazným neproporcionálním způsobem jako *MSE* velké chyby, a proto ji někteří autoři doporučují pro *ocenění předpovědních chyb* v časových řadách s odlehlými pozorováními.

Všechny dosud uvedené míry závisí na měřítku předpovídané proměnné a lze je tedy použít, jen když navzájem porovnáváme různé předpovědní techniky v téže časové řadě. Nyní uvedeme další míry, které již na měřítku předpovídané proměnné nezávisí:

(5) *Střední absolutní procentní chyba MAPE (mean absolute percentage error)*:

$$MAPE = \frac{100}{h} \sum_{t=n+1}^{n+h} \left| \frac{y_t - \hat{y}_t}{y_t} \right|, \quad (3.17)$$

obvykle nabývá hodnot od 0 do 100 % a je mnohými autory preferována (viz např. Makridakis (1993)). Výsledek menší než 100 % znamená, že daný předpovědní model je lepší než model náhodné procházky s předpověďmi trvale na nulové úrovni, tj. trvale s  $MAPE = 100\%$ . Pro hodnoty časové řady pohybující se blízko nuly však není toto kritérium příliš spolehlivé.

(6) Korigovaná střední absolutní procentní chyba AMAPE (adjusted MAPE):

$$AMAPE = \frac{100}{h} \sum_{t=n+1}^{n+h} \left| \frac{(y_t - \hat{y}_t)}{(y_t + \hat{y}_t)/2} \right|, \quad (3.18)$$

koriguje asymetrii kritéria (3.17): dává totiž stejný výsledek i po záměně skutečných hodnot s jejich předpověďmi (skutečná hodnota 0,7 a předpověď 0,9 přispějí do součtu v (3.18) stejně jako skutečná hodnota 0,9 a předpověď 0,7).

(7) Theilova U-statistika (viz Theil (1966)):

$$U = \frac{\sqrt{\frac{1}{h} \sum_{t=n+1}^{n+h} (y_t - \hat{y}_t)^2}}{\sqrt{\frac{1}{h} \sum_{t=n+1}^{n+h} \hat{y}_t^2 + \frac{1}{h} \sum_{t=n+1}^{n+h} y_t^2}}, \quad (3.19)$$

(je ovšem možná obecnější formulace založená na předpovědi z nějakého jednoduchého či naivního modelu označovaného jako benchmark); hodnota  $U$  leží vždy mezi 0 a 1, přičemž hodnota 0 značí perfektní shodu předpovědi se skutečností.

Další skupina měř pro chyby v předpovědích se omezuje pouze na posouzení toho, jak model předpovídá znaménka budoucích hodnot (tj. zda tyto hodnoty budou kladné či záporné) nebo změny ve směru vývoje budoucích hodnot (tj. zda růst přejde v pokles apod.). Takové předpovědi jsou často ze strategického hlediska důležitější než numerické předpovědi:

(8) Procento správných předpovědí znaménka:

$$\frac{100}{h} \sum_{t=n+1}^{n+h} z_t, \text{ kde } z_t = \begin{cases} 1 & \text{pro } y_t \cdot \hat{y}_t > 0, \\ 0 & \text{jinak.} \end{cases} \quad (3.20)$$

(9) Procento správných (jednokrokových) předpovědí změn ve směru vývoje:


$$\frac{100}{h} \sum_{t=n+1}^{n+h} z_t, \text{ kde } z_t = \begin{cases} 1 & \text{pro } (y_t - y_{t-1}) \cdot (y_t - \hat{y}_t) > 0, \\ 0 & \text{jinak.} \end{cases} \quad (3.21)$$

Pro jistotu ještě jednou zdůrazněme, že uvedená kritéria svědčí pouze o statistické přesnosti předpovědi a nikoli o její ekonomické či finanční adekvátnosti. Např. malá hodnota MSE ještě nemusí znamenat, že máme k dispozici úspěšný návod, jak predikovat budoucí tržní strategie (např. někdy je ze strategických důvodů žádoucí podhodnotit, či naopak nadhodnotit budoucí vývoj apod.).“ (Cipra, 2013, str. 245-247)

## 4 Ověření a porovnání zvolených metod

V této kapitole jsou popsány a porovnány výsledky predikce tržeb vybrané firmy dosažené pomocí vybraných metod a přístupů. Všechny metody vychází ze stejné časové řady tržeb, která je zaznamenána v obrázku 4.1 a lze pozorovat, že tržby v daném období nemají jasný vývojový trend. Dále je zřejmý výrazný rozdíl mezi střední hodnotou tržeb v letech 2010 až 2013 a střední hodnotou tržeb ve zbytku období. Výrazná je také odlehlá hodnota v prvním měsíci roku 2018, kdy hodnota tržeb dosáhla téměř 250 milionů Kč. Tato hodnota byla zapříčiněna vnitropodnikovou situací, kdy vybraná dceřiná firma převzala povinnosti ostatních poboček. Dále do všech zvolených modelů nebudou vstupovat data za rok 2018 a to z důvodu, že výsledky budou predikce porovnávány s reálnými hodnotami právě roku 2018.

Obr. 4.1: Tržby za období 2010-2018 (mil. Kč)




### 4.1 Regresní model

Pro potřeby regresního modelu byly jako vysvětlující proměnné vybrány následující veličiny: tržní cena hliníku, index produkce polského automobilového průmyslu a kurz české Koruny vůči polskému Zlotému. Předpokládané chování regresních koeficientů souvisí s aktivitami vybrané firmy a lze tedy předpokládat, že s růstem jedné z vysvětlujících proměnných, za podmínek ceteris paribus, budou růst také tržby. V tabulce 4.1 jsou zachyceny vybrané deskriptivní statistiky jednotlivých veličin modelu, a lze z ní vyčíst, že směrodatná odchylka proměnné tržby dosahuje


hodnoty zhruba 46,5 mil. Kč, což značí výraznou variabilitu časové řady. Poměrně variabilní je také tržní cena hliníku, jejíž směrodatná odchylka je v daném období 277,87 USD/t.

Z obrázků 4.1 až 4.4 je zřejmé, že všechny veličiny vybraného modelu jsou nestacionární, což potvrzuje i obrázek 4.5 autokorelačních funkcí jednotlivých veličin. Stacionarita je přitom jedním z předpokladů pro použití metody nejmenších čtverců a je tedy nutné tyto veličiny upravit, a to pomocí prvních diferencí. Autokorelační funkce upravených časových řad lze vidět na obrázku 4.6, kde až na výjimku proměnné index automobilového průmyslu, splňují upravené časové řady podmínku stacionarity.


Obr. 4.2: Tržní cena hliníku (USD/t)



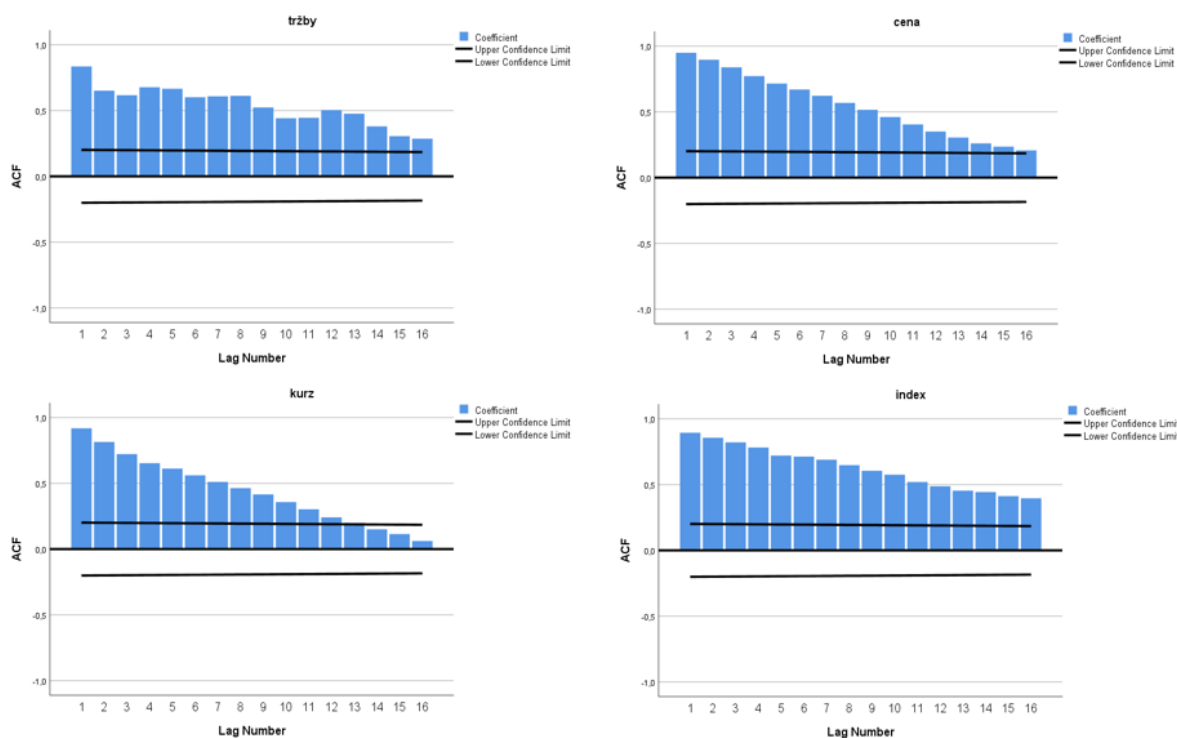
Obr. 4.3 Kurz PLN/CZK



Obr. 4.4: Index produkce polského automobilového průmyslu



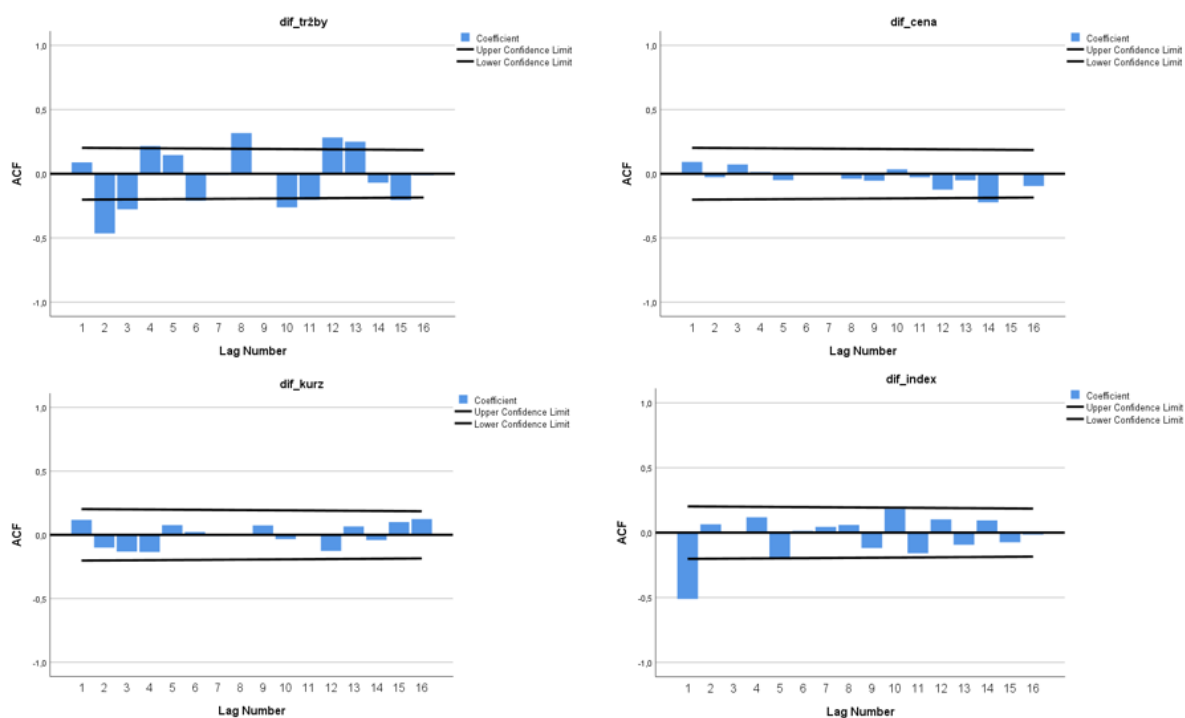
Obr. 4.5 Autokorelační funkce proměnných modelu



Tab. 4.1: Deskriptivní statistiky proměnných modelu


Deskriptivní statistiky						
	N	Variační rozpětí	Minimum	Maximum	Střední hodnota	Směrodatná odchylka
tržby (mil. Kč)	96	185,312	5,390	190,702	53,851	46,529
cena (USD/t)	96	1199,524	1467,893	2667,417	1943,382	277,866
kurz (PLN/CZK)	96	1,131	5,683	6,814	6,248	0,241
Index (body)	96	52,700	69,800	122,500	92,964	13,420

Obr. 4.6: Autokorelační funkce upravených časových řad



Obrázek 4.7 znázorňuje závislosti mezi jednotlivými proměnnými. Z obrázku je zřejmé, že mezi vysvětlovanou a vysvětlujícími proměnnými není lineární závislost, a naopak je velmi pravděpodobné, že mezi proměnnými neexistuje žádná závislost.

Obr. 4.7: Bodový diagram závislosti proměnných



I přes poměrně jasné výsledky grafického testu závislostí, je odhadnut lineární regresní model, jehož hodnoty jsou zaznamenány v tabulce 4.2. Z tabulky je zřejmé,




že výsledný model má dle hodnoty koeficientu determinance (R Square) minimální vypovídací hodnotu o variabilitě tržeb v závislosti na vybraných vysvětlujících veličinách. Proměnné modelu byly dále upraveny a různě kombinovány s cílem dosáhnout lepších hodnot. Nicméně ve všech případech byl model, i jednotlivé vysvětlující proměnné, statisticky nevýznamný a to dle posledního sloupce tabulky, kde by hodnoty signifikance měly dosahovat hodnot menších než je zvolená hladina významnosti. Lze tedy tvrdit, že variabilitu tržeb nelze vysvětlit pomocí vybraných veličin.

Tab. 4.2 Odhad lineárního regresního modelu

Model Summary <sup>b</sup>						
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson	Sig.
1	,059 <sup>a</sup>	0,004	-0,029	26,55574	1,796	0,956
a. Predictors: (Constant), dif_index, dif_kurz, dif_cena						
b. Dependent Variable: dif_tržby						
Coefficients <sup>a</sup>						
Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	0,101	2,743		0,037	0,971
	dif_cena	0,005	0,034	0,017	0,156	0,876
	dif_kurz	14,237	29,338	0,052	0,485	0,629
	dif_index	0,057	0,557	0,011	0,103	0,918

Zdroj: Vlastní zpracování v softwaru SPSS

Obr. 4.8: Průměrné hodnoty tržeb ve vybraných obdobích




Z důvodu nepříznivých výsledků regresního modelu, byla časová řada vstupních dat zkrácena. Dalším z důvodů je výrazný rozdíl mezi středními hodnotami v rámci různých intervalů vybraného období. Jak lze vidět v obrázku 4.8, během prvních tří let období, činily průměrné tržby přibližně 103 mil. Kč. V následujících 2 letech klesla střední hodnota tržeb o zhruba dvě třetiny vůči průměru předchozích let. Další pokles byl zaznamenán také v letech 2015 až 2017 kdy se průměrná výše tržeb propadla o jednu třetinu oproti předchozímu intervalu.

Pro další potřeby této práce je tedy časová řada rozdělena na tři dílčí řady, a to konkrétně na celé období mezi lety 2010 a 2017, na období mezi lety 2013 a 2017 a na období mezi lety 2015 a 2017. Z tohoto rozdělení časových řad se bude vycházet nejen v rámci regresního modelu, ale také v případě ostatních vybraných modelů a postupů.

#### 4.1.1 Regresní modely zkrácených období

V obrázcích 4.9 a 4.10 jsou zachyceny závislosti mezi jednotlivými proměnnými v rámci dílčích časových řad. Z obou obrázků je zřejmé, že zkrácení souboru vstupních dat nevedlo k lepším výsledkům.

Obr. 4.9: Bodový diagram závislostí pro období 2013-2017



V tabulce 4.3 jsou zachyceny výsledky odhadu lineárního regresního modelu pro období 2013 až 2017, přičemž z hodnot v tabulce je jasné, že daný model opět není

statisticky významný a nemá žádnou vypovídací hodnotu o variabilitě tržeb. Lepších výsledků nebylo dosaženo ani po úpravě dat a vyzkoušení různých kombinací.

V případě období mezi roky 2015 a 2017 byl odhadnutý regresní model, který by obsahoval všechny vysvětlující proměnné také statisticky nevýznamný, jak lze vidět v tabulce 4.4.

Tab. 4.3: Odhad regresního modelu pro období 2013-2017


Model Summary <sup>b</sup>						
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson	Sig.
2	,222 <sup>a</sup>	0,049	-0,003	7,43422	2,152	0,423
a. Predictors: (Constant), dif_index, dif_cena, dif_kurz						
b. Dependent Variable: dif_tržby						
Coefficients <sup>a</sup>						
Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
2	(Constant)	-0,034	0,976		-0,035	0,972
	dif_cena	0,023	0,016	0,191	1,420	0,161
	dif_kurz	3,877	10,051	0,052	0,386	0,701
	dif_index	0,108	0,175	0,082	0,619	0,539

Zdroj: Vlastní zpracování v softwaru SPSS

Na základě výsledků z tabulek 4.2 až 4.4 lze tvrdit, že se potvrdila úvaha dle obrázku 4.7, že mezi vybranými proměnnými není statisticky významná závislost. Vybranou časovou řadu nelze s dostatečnou přesností predikovat pomocí vícerozměrných lineárních regresních modelů s vybranými vysvětlujícími proměnnými.

Vzhledem k tomu, že ani jeden ze tří modelů není statisticky významný a vysvětlující proměnné také nejsou statisticky významné, nemá smysl tyto regresní modely dále testovat a ověřovat podmínky homoskedasticity, multikolinearity a dalších předpokladů.

Obr. 4.10: Bodový diagram závislostí pro období 2015-2017



Tab 4.4: Odhad regresního modelu pro období 2015-2017

Model Summary <sup>b</sup>						
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson	Sig.
3	,363 <sup>a</sup>	0,131	0,047	7,21516	2,523	0,308
a. Predictors: (Constant), dif_index, dif_cena, dif_kurz						
b. Dependent Variable: dif_tržby						
Coefficients <sup>a</sup>						
Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
3	(Constant)	-1,312	1,267		-1,035	0,308
	dif_kurz	-8,445	13,062	-0,121	-0,647	0,523
	dif_cena	0,055	0,026	0,387	2,084	0,045
	dif_index	0,092	0,250	0,063	0,368	0,715

Zdroj: Vlastní zpracování v softwaru SPSS

## 4.2 Model interpolace a „vyhlazování“

V rámci této metody byla pro jednotlivá zvolená období hledána funkce, která by svým průběhem nejlépe popisovala reálný průběh tržeb v daném období. Údaje v tabulce 4.5 zachycují výsledky interpolací pomocí jednotlivých typů funkcí. Z tabulky

je zřejmé, že dle koeficientu determinance lze vývoj tržeb ve všech obdobích nejlépe popsat kubickou funkcí.

Tab. 4.5: Výsledky koeficientu determinance pro jednotlivé funkce

Model Summary			
Equation	R Square		
	Tržby 2010-2017	Tržby 2013-2017	Tržby 2015-2017
Linear	0,465	0,278	0,226
Logarithmic	0,241	0,248	0,263
Inverse	0,003	0,202	0,303
Quadratic	0,466	0,294	0,641
Cubic	0,616	0,294	0,641
Compound	0,560	0,269	0,133
Power	0,288	0,246	0,161
S	0,002	0,206	0,190
Growth	0,560	0,269	0,133
Exponential	0,560	0,269	0,133
Logistic	0,560	0,269	0,133

Zdroj: Vlastní zpracování v softwaru SPSS

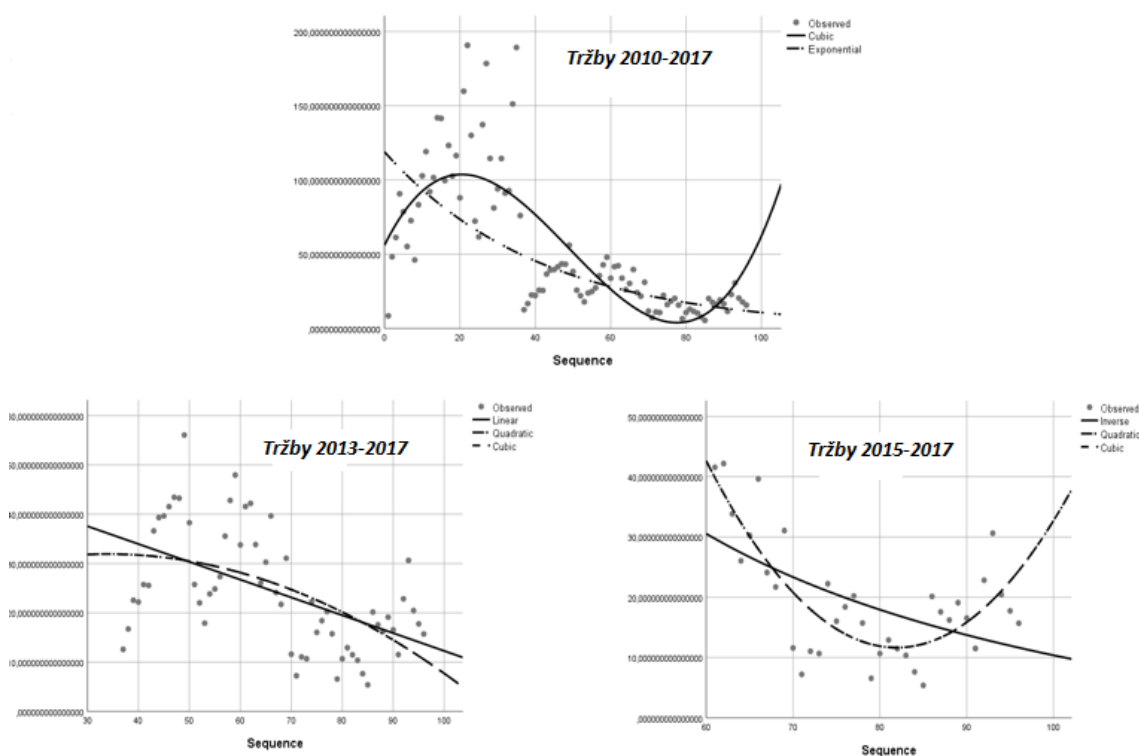
Pro lepší přehlednost byly vytvořeny grafy, které jsou zachyceny v obrázku 4.11. Jednotlivé grafy znázorňují křivky vybraných funkcí, stanovených k popisu vývoje reálné hodnoty tržeb v daných obdobích.

Z obrázku 4.11 je zřejmé, že vývoj tržeb za období posledních osmi let, se podobá průběhu kubické funkce. Nicméně reálný vývoj lze také popsat pomocí exponenciální funkce. Oproti tomu období posledních pěti a tří let lze popsat kvadratickou funkcí, jejíž průběh je shodný v případě pětiletého období s konkávní částí kubické funkce, a v případě tříletého období s konvexní částí kubické funkce. Obě období pak lze popsat také pomocí inverzní funkce. Z obrázku je také patrné, že křivky kubických funkcí mají poměrně vysoký pozitivní sklon v predikovaném období, tedy až na výjimku křivky pro tržby za posledních pět let.

Na základě závislostí z tabulky a grafické analýzy budou predikované hodnoty stanoveny pomocí dvou funkcí. V prvním případě to bude pro všechna období kubická funkce. V druhém případě funkce s druhým nejvyšším koeficientem determinance.

V tabulce 4.6 jsou zachyceny výsledky predikce pomocí kubické funkce, přičemž z tabulky je zřejmé, že se potvrdila očekávaná nepřesnost odhadu u modelů, s příliš vysokým pozitivním sklonem funkce v období predikce. Naopak nejpresnějších hodnot predikce bylo dosaženo v rámci modelu pro tržby za posledních 5 let.

Obr. 4.11: Grafy křivek funkcí vybraných pro daná období



Tab. 4.6: Predikce pomocí kubické funkce (v mil. Kč)

T	Tržby 2010-2017	Tržby 2013-2017	Tržby 2015-2017	Reálné tržby
I.18	46,510	9,853	26,311	240,272
II.18	51,458	9,149	28,319	11,942
III.18	56,722	8,432	30,456	14,798
IV.18	62,307	7,704	32,722	12,328
V.18	68,220	6,966	35,116	10,717
VI.18	74,468	6,216	37,640	14,103
VII.18	81,057	5,456	40,292	18,217
VIII.18	87,994	4,683	43,074	19,975
IX.18	95,285	3,901	45,984	16,870
X.18	102,937	3,107	49,023	2,313
<b>MAE</b>	62,132	7,471	24,596	
<b>RMSE</b>	61,33	8,435	24,757	
<b>AMAPE</b>	137,941 %	70,395 %	95,766 %	

V tabulce 4.7 jsou zaznamenány výsledky predikce pomocí jiných funkcí. Predikce pomocí jiné, než kubické funkce vedla k výrazně lepším výsledkům. Nejmenší střední chyba odhadu predikce od reálné hodnoty byla opět v rámci modelu za období 2013 až 2017. Nicméně i pro odhady v rámci ostatních dílčích časových řad šlo o poměrně nízké absolutní hodnoty odchylky predikované hodnoty od reálné výše tržeb. Lze tedy tvrdit, že vybrané funkce jsou pro predikci zvolených časových

vhodnější, než kubická funkce.

Tab. 4.7: Predikce pomocí jiných funkcí (v mil. Kč)

T	Exponenciální fce Tržby 2010-2017	Lineární fce Tržby 2013-2017	Inverzní fce Tržby 2015-2017	Reálné tržby
I.18	11,542	13,349	11,318	240,272
II.18	11,267	12,987	11,000	11,942
III.18	11,000	12,626	10,688	14,798
IV.18	10,738	12,265	10,383	12,328
V.18	10,483	11,903	10,083	10,717
VI.18	10,234	11,542	9,790	14,103
VII.18	9,991	11,180	9,502	18,217
VIII.18	9,754	10,819	9,220	19,975
IX.18	9,522	10,458	8,943	16,870
X.18	9,296	10,096	8,671	2,313
<b>MAE</b>	4,771	4,157	5,078	
<b>RMSE</b>	5,544	4,988	5,792	
<b>AMAPE</b>	42,903 %	37,212 %	45,949 %	

### 4.3 Modely dekompozice časové řady

V rámci této metody jsou stanoveny trendové složky dílčích časových řad pomocí metody klouzavých průměrů. Následně jsou stanoveny sezónní faktory dle aditivní nebo multiplikativní vazby.

#### 4.3.1 Kombinace sezónního faktoru a modelu interpolace

Hodnoty predikce jsou stanoveny jako součin sezónního faktoru a sezónně očištěné hodnoty predikce stanovené pomocí lineární interpolace. V tabulce 4.8 jsou zachyceny výsledky sezónních faktorů pro jednotlivá období a pro multiplikativní a aditivní vazbu. Z tabulky je zřejmé, že sezónní faktory stanovené v rámci aditivní metody se pro zvolená období výrazně liší. Podobně je tomu také u multiplikativní vazby.

V tabulce 4.9 lze vidět predikované hodnoty pomocí výše popsaného postupu. Z tabulky je zřejmé, že nalezený lineární trend sezónně očištěné řady není vhodný pro predikci tržeb. V případě aditivní i multiplikativní metody se predikované hodnoty po většinu období predikce pohybují pod úrovní 0, tedy na reálně nedosažitelné úrovni.

Pro zpřesnění predikce byla jako výchozí predikovaná hodnota časově očištěné řady zvolena hodnota stanovená pomocí interpolace exponenciální funkcí pro multiplikativní vazbu, a interpolací kubickou funkcí pro aditivní vazbu.

Nové výsledky predikce jsou zachyceny v tabulce 4.10, kde lze vidět, že až na výjimku v druhém měsíci roku 2018 se predikované tržby při použití multiplikativní vazby pohybovaly kolem hodnoty 10 mil. Kč, což přibližně odpovídá reálnému vývoji.

Tab. 4.8: Sezónní faktory

typ	Multiplikativní 2010-2017	Aditivní 2010-2017	Multiplikativní 2013-2017	Aditivní 2013-2017
Perioda	Sezónní faktor (%)	Sezónní faktor	Sezónní faktor (%)	Sezónní faktor
1	76,39	-14,46	91,10	2,82
2	127,14	4,72	131,83	5,64
3	109,35	7,42	103,73	-1,43
4	88,77	-8,62	91,12	-3,87
5	90,63	-7,84	107,51	-2,23
6	92,74	-6,59	107,36	0,37
7	90,21	-2,74	78,49	-3,87
8	85,01	-12,41	90,02	-1,32
9	113,20	6,62	112,65	3,64
10	123,11	20,98	103,14	0,80
11	118,48	21,19	102,03	1,32
12	84,97	-8,27	81,01	-1,86

Tab 4.9: Lineární predikce za období 2010-2017 (v mil. Kč)

T	Lineární fce multiplikativní vazba	Lineární fce aditivní vazba	Reálné tržby
I.18	-0,900	-16,860	240,272
II.18	-2,930	1,140	11,942
III.18	-3,760	2,690	14,798
IV.18	-4,060	-14,030	12,328
V.18	-5,160	-14,890	10,717
VI.18	-6,330	-14,470	14,103
VII.18	-7,180	-12,100	18,217
VIII.18	-7,730	-22,940	19,975
IX.18	-11,560	-5,080	16,870
X.18	-12,750	8,120	2,313
<b>MAE</b>	20,302	22,715	
<b>RMSE</b>	19,878	23,888	
<b>AMAPE</b>	492,458 %	2729,026 %	

Oproti tomu odhady hodnot pro aditivní vazbu se výrazně lišily oproti reálným hodnotám, a to kvůli interpolace kubickou funkcí, jejíž nevýhody byly zmíněny již



v podkapitole 4.2.

Tab. 4.10: Predikce pomocí jiných funkcí za období 2010-2017 (v mil. Kč)

T	Exponenciální fce multiplikativní vazba	Kubická fce aditivní vazba	Reálné tržby
I.18	8,880	28,640	240,272
II.18	14,420	52,420	11,942
III.18	12,120	60,060	14,798
IV.18	9,600	49,740	12,328
V.18	9,560	55,590	10,717
VI.18	9,550	63,030	14,103
VII.18	9,070	72,750	18,217
VIII.18	8,340	69,600	19,975
IX.18	10,830	95,480	16,870
X.18	10,500	117,040	2,313
<b>MAE</b>	5,400	57,161	
<b>RMSE</b>	6,044	58,543	
<b>AMAPE</b>	48,236 %	132,485 %	

Tab. 4.11: Lineární predikce za období 2013-2017 (v mil. Kč)

T	Lineární fce multiplikativní vazba	Lineární fce aditivní vazba	Reálné tržby
I.18	11,990	16,340	240,272
II.18	16,860	18,790	11,942
III.18	12,880	11,370	14,798
IV.18	10,970	8,580	12,328
V.18	12,540	9,860	10,717
VI.18	12,120	12,100	14,103
VII.18	8,570	7,510	18,217
VIII.18	9,490	9,700	19,975
IX.18	11,450	14,310	16,870
X.18	10,100	11,110	2,313
<b>MAE</b>	5,038	5,469	
<b>RMSE</b>	5,744	6,177	
<b>AMAPE</b>	44,157 %	47,802 %	

Přesnějších výsledků naopak dosahovaly hodnoty predikované v případě kratšího období, tedy mezi lety 2013 a 2017. Jak lze vidět v tabulce 4.11 predikované hodnoty se jak v rámci multiplikativní, tak v rámci aditivní vazby pohybují v intervalu od osmi do devatenácti milionů korun. Nejmenší rozdíl mezi predikovanou a reálnou hodnotou byl v případě aditivní vazby v pátém měsíci roku 2018, kdy odchylka od

reálné hodnoty byla menší než 1 mil. Kč. Pro multiplikativní vazbu to pak byla odchylka ve výši 1,35 mil. Kč. Střední chyba odhadu predikce pro multiplikativní vazbu je přibližně 5 mil. Kč. V rámci aditivní vazby je střední chyba odhadu přibližně 5,5 mil Kč.

#### 4.3.2 Metoda exponenciálního vyrovňování

Tato metoda také vychází ze sezónně očištěných časových řad, avšak následná predikce je stanovena podle Brownovy metody, tedy dle vzorce (2.42). Tabulka 4.12 zachycuje hodnoty sezónních faktorů potřebných pro použití zvolené metody. V tabulce lze vidět, že sezónní faktory stanovené z období 2010-2017 a 2013-2017 se výrazně neliší. Oproti tomu pak sezónní faktory stanovené z období 2015-2017 se výrazně liší oproti přechozím obdobím, a to zejména pro prvních 5 period.

Tab. 4.12: Sezónní faktory pro jednotlivé dílčí řady

perioda	Sezónní faktor 2010-2017	Sezónní faktor 2013-2017	Sezónní faktor 2015-2017
1	0,781	0,896	0,588
2	1,158	1,298	1,653
3	1,010	0,996	1,295
4	0,864	0,949	1,308
5	0,929	0,996	1,347
6	0,959	0,958	1,006
7	0,936	0,842	0,594
8	0,950	1,043	0,899
9	1,250	1,260	1,200
10	1,214	1,011	0,760
11	1,135	0,938	0,672
12	0,813	0,813	0,679

V tabulce 4.13 lze vidět reálné hodnoty tržeb a predikované hodnoty pomocí exponenciálního vyrovňování. Na základě údajů z tabulky lze jednoznačně rozhodnout, že v rámci modelu za roky 2010 až 2017 je vývoj predikovaných hodnot podobný vývoji reálnému. V rámci července a srpna roku 2018 se predikované hodnoty jen mírně lišily od reálných tržeb. Dokonce v srpnu byla odchylka predikce od reálné hodnoty pouhých 86 tis. Kč. Průměrná absolutní odchylka od reálné hodnoty je pak 7,77 mil. Kč.


Podobných výsledků bylo dosaženo i v rámci modelu pro kratší časové období,

tedy pro roky 2013-2017. Střední chyba odhadu pro tento model nabývá hodnoty přibližně 7 mil. Kč, což je o něco málo lepší, než u předchozího model a podobně tomu bylo i pro konkrétní hodnotu predikce v srpnu 2018, kde je rozdíl predikce od reálné hodnoty pouze 44 tis. Kč.

Tab. 4.13: Predikované hodnoty dle exponenciálního vyrovňování (v mil. Kč)

T	Tržby 2010-2017	Tržby 2013-2017	Tržby 2015-2017	Realné tržby
I.18	15,073	17,488	14,708	240,272
II.18	22,642	25,287	41,773	11,942
III.18	20,005	19,364	33,058	14,798
IV.18	17,343	18,404	33,740	12,328
V.18	18,893	19,269	35,099	10,717
VI.18	19,752	18,477	26,468	14,103
VII.18	19,506	16,208	15,796	18,217
VIII.18	20,061	20,019	24,133	19,975
IX.18	26,711	24,118	32,539	16,870
X.18	26,258	19,302	20,802	2,313
<b>MAE</b>	7,768	7,023	16,332	
<b>RMSE</b>	9,682	8,206	17,435	
<b>AMAPE</b>	48,251 %	47,369 %	78,247 %	

Obr. 4.12: Rozdíl mezi jednotlivými predikovanými hodnotami



Výrazně horší výsledky jsou však dosaženy v rámci nejkratšího období, tedy v letech 2015 až 2017. Jak lze vidět v tabulce 4.13, rozdíly mezi predikovanou a reálnou výší tržeb jsou větší, než v předchozích dvou případech. Vliv na to má pravděpodobně velice malý počet pozorování v rámci této dílčí časové řady. Střední chyba odhadu je více než dvojnásobná oproti předchozím modelům a to konkrétně

16,33 mil. Kč. Nejmenší absolutní odchylka je v tomto případě v rámci sedmého měsíce. Nejedná se však už o odchylku v tisících Kč, ale konkrétně o 2,42 mil. Kč. Rozdílné hodnoty predikce oproti předchozím dvěma modelům lze vidět v obrázku 4.12, kde je patrný výrazný rozdíl zejména v první polovině sledovaného období. Oproti tomu však v druhé polovině jsou rozdíly mezi jednotlivými modely méně výrazné.


## 4.4 LFL Forecaster

Pro další odhady tržeb byl využit software LFL Forecaster<sup>3</sup>, který pracuje s tzv. Fuzzy logikou a Fuzzy transformací. Více informací o Fuzzy přístupu v podkapitole (2.4).

V obrázku 4.13 je zaznamenán grafický výstup softwaru pro časovou řadu za roky 2010 až 2018 a pro časovou řadu za období od 2013 do 2018. Černá křivka znázorňuje reálné hodnoty tržeb v rámci daného období. Červená křivka pak zobrazuje hodnoty predikce. Interval se žlutým pozadím je tzv. „learning“ interval, v rámci kterého software propočítává jednotlivé proměnné, které pak vstupují do intervalu se zeleným pozadím, tzv. „validation“ interval, ve kterém se ověřují výsledky z learning intervalu. Interval s červeným pozadím je tzv. „forecast“ interval, který je shodný s obdobím pro predikci. Pro obě časové řady byl jako validation interval zvolen rok 2017. Jako learning interval pak celé období před rokem 2017. Období predikce zůstává stejné, tedy prvních 10 měsíců roku 2018.


Pro lepší grafické znázornění byly vytvořeny obrázky 4.14 a 4.15, ve kterých jsou zachyceny hodnoty odhadu pomocí softwaru LFL forecaster a reálné výše tržeb pro validation a forecast interval.

Obr. 4.13: Grafický výstup LFL Forecaster




<sup>3</sup> Demo verze softwaru LFL Forecaster dostupná na [http://irafm.osu.cz/en/c110\\_lfl-forecaster/](http://irafm.osu.cz/en/c110_lfl-forecaster/)

Obr. 4.14: Reálné a predikované tržby z časové řady 2010-2018



Z obrázku 4.14 je zřejmé, že hodnoty predikce jsou výrazně rozdílné oproti reálné výši tržeb. Střední chyba odhadu je v tomto případě 24,69 mil. Kč, což je oproti některým předchozím modelům několikanásobně vyšší hodnota. Nicméně vývoj predikovaných hodnot se do jisté míry podobá reálnému vývoji tržeb, což můžeme brát jako pozitivní prvek tohoto modelu.


Obr. 4.15: Reálné a predikované tržby z časové řady 2013-2018



Oproti tomu z obrázku 4.15 je patrné, že kratší při stanovení kratšího learning intervalu je výsledná křivka hodnot odhadu téměř rovnoběžná s osou X, přičemž hodnoty pro jednotlivá období jen lehce oscilují okolo střední hodnoty predikce, tedy

14,15 mil. Kč. V obrázku 4.16 pak lze vidět vývoj predikovaných hodnot tržeb, který se tvarem křivky opět podobá reálnému vývoji tržeb. Střední chyba odhadu je v případě tohoto modelu 3,64 mil. Kč, což je výrazně lepší hodnota než v předchozím případě. Dokonce ve dvou případech se predikovaná hodnota oproti reálné lišila o méně než 1 mil. Kč. Konkrétně v třetím měsíci byla absolutní odchylka 639 tis. Kč a v šestém měsíci pak 73 tis. Kč. Jednotlivé hodnoty predikce jsou zaznamenány v tabulce 4.14, ze kterých lze potvrdit, že predikce dle kratší časové řady byla oproti predikci z časové řady 2010 až 2017 výrazně přesnější.

Obr. 4.16: Predikované hodnoty z časové řady 2013-2018



Tab. 4.14: Predikce dle LFL Forecaster (v mil. Kč)

T	Tržby 2010-2017	Tržby 2013-2017	Reálné tržby
I.18	26,431	14,361	240,272
II.18	32,926	14,117	11,942
III.18	42,192	14,159	14,798
IV.18	45,836	14,182	12,328
V.18	42,974	14,134	10,717
VI.18	40,924	14,177	14,103
VII.18	45,814	14,260	18,217
VIII.18	38,341	14,072	19,975
IX.18	28,186	13,943	16,870
X.18	26,292	14,112	2,313
<b>MAE</b>	24,692	3,638	
<b>RMSE</b>	24,239	4,675	
<b>AMAPE</b>	98,846 %	31,648 %	

## 4.5 Jednoduchá predikce průměrem

V rámci této metody jsou hodnoty predikce stanoveny jako střední hodnota tržeb v rámci vybrané časové řady. Odhadované výše tržeb jsou tak pro každý měsíc období predikce stejné, viz tabulka 4.15. Období 2010 až 2017 nebylo v rámci tohoto postupu zahrnuto z důvodu velkého rozdílu mezi hodnotami v letech 2010 až 2012 a ve zbytku období (viz obr. 4.8).

Tab 4.15: Predikce průměrem (v mil. Kč)

T	Tržby 2013-2017	Tržby 2015-2017	Reálné tržby
I.18	24,370	19,520	240,272
II.18	24,370	19,520	11,942
III.18	24,370	19,520	14,798
IV.18	24,370	19,520	12,328
V.18	24,370	19,520	10,717
VI.18	24,370	19,520	14,103
VII.18	24,370	19,520	18,217
VIII.18	24,370	19,520	19,975
IX.18	24,370	19,520	16,870
X.18	24,370	19,520	2,313
MAE	10,897	6,147	
RMSE	11,327	7,371	
AMAPE	62,733 %	43,634 %	

Z tabulky 4.15 je zřejmé, že jednoduchá predikce na základě průměrných hodnot časové řady, je přesnější, když vycházíme ze střední hodnoty za roky 2015 až 2017. Střední chyba odhadu z dat za roky 2015-2017 je téměř poloviční, oproti střední chybě odhadu z dat za období 2013 až 2017. Když tuto metodu srovnáme s ostatními předchozími metodami, tak je dle vybraných ukazatelů přesnější, než např. většina metod, jenž vychází z dat za roky 2010 až 2017.

## 4.6 Porovnání výsledků jednotlivých metod

V rámci této podkapitoly jsou porovnány výsledky predikce pomocí vybraných metod. Při stanovení ukazatelů střední chyby odhadu a dalších ukazatelů (viz podkapitola 3.2) byly vyloučeny hodnoty pro první měsíc predikce, tedy leden 2018, kdy byla zaznamenána extrémní výše tržeb. Výsledky hodnot zvolených ukazatelů jsou pro jednotlivé modely zaznamenány v tabulkách 4.16 a 4.17 a jednotlivé modely jsou v rámci této podkapitoly označeny dle seznamu zkratk.

V tabulce 4.15 jsou zachyceny hodnoty absolutních odchylek predikce od reálné

hodnoty. Z tabulky je zřejmé, že extrémní hodnotu reálných tržeb v prvním měsíci roku 2018 nešlo žádným ze zvolených způsobů predikovat. Pro lepší znázornění absolutních odchylek pro jednotlivé modely byly vytvořeny obrázky 4.17 až 4.19. V rámci těchto obrázků je pozorováno, pro kterou z metod se absolutní odchylky odhadu nejvíce přibližují ose X, která znázorňuje nulovou hodnotu rozdílu mezi predikovanou a reálnou výší tržeb. Dále jsou také vynechány hodnoty pro leden 2018, kde reálné tržby dosahovaly výrazně nadprůměrné výše. Hodnoty ukazatelů v případě výpočtu s hodnotami za leden 2018 jsou pro srovnání uvedeny v přílohách č. 5 a 6.

Tab. 4.15: Absolutní odchylky predikovaných hodnot od reálných tržeb

měsíc	Absolutní odchylky predikce od reálné hodnoty (mil. Kč)									
	1	2	3	4	5	6	7	8	9	10
INT8Y	193,761	39,517	41,923	49,979	57,503	60,365	62,841	68,020	78,415	100,624
INT5Y	230,418	2,794	6,367	4,624	3,751	7,887	12,761	15,291	12,969	0,794
INT3Y	213,960	16,378	15,658	20,394	24,399	23,537	22,076	23,099	29,114	46,710
INT8Y(2)	228,730	0,675	3,798	1,590	0,234	3,869	8,226	10,221	7,348	6,983
INT5Y(2)	226,923	1,045	2,172	0,063	1,186	2,561	7,037	9,156	6,412	7,783
INT3Y(2)	228,954	0,942	4,110	1,945	0,634	4,313	8,715	10,755	7,927	6,358
Dmult8Y	241,172	14,872	18,558	16,388	15,877	20,433	25,397	27,705	28,430	15,063
Dadit8Y	257,132	10,802	12,108	26,358	25,607	28,573	30,317	42,915	21,950	5,807
Dmult8Y(2)	231,392	2,478	2,678	2,728	1,157	4,553	9,147	11,635	6,040	8,187
Dadit8Y(2)	211,632	40,478	45,262	37,412	44,873	48,927	54,533	49,625	78,610	114,727
Dmult5Y	228,282	4,918	1,918	1,358	1,823	1,983	9,647	10,485	5,420	7,787
Dadit5Y	223,932	6,848	3,428	3,748	0,857	2,003	10,707	10,275	2,560	8,797
LSE8Y	225,198	10,700	5,207	5,015	8,176	5,649	1,289	0,087	9,841	23,946
LSE5Y	222,784	13,345	4,565	6,076	8,552	4,374	2,009	0,045	7,248	16,989
LSE3Y	225,564	29,831	18,259	21,412	24,382	12,366	2,420	4,159	15,669	18,489
LFL8Y	213,840	20,984	27,394	33,508	32,257	26,821	27,598	18,366	11,316	23,980
LFL5Y	225,910	2,175	0,639	1,854	3,417	0,074	3,957	5,902	2,927	11,799
E(x)5Y	215,901	12,429	9,572	12,043	13,653	10,268	6,154	4,396	7,501	22,058
E(x)3Y	220,752	7,578	4,721	7,192	8,803	5,417	1,303	0,455	2,650	17,207


Z obrázku 4.17 lze potvrdit, že nejpřesnějšími metodami v rámci časové řady za roky 2010 až 2018 byly metody interpolace exponenciální funkce, kombinace exponenciální interpolace a sezónního faktoru a metoda exponenciální vyrovnávání. Pro ostatní metody je rozdíl mezi absolutní odchylkou a nulovou hodnotou mnohem výraznější.

V obrázku 4.18 jsou zaznamenány hodnoty absolutních odchylek pro modely, jenž vycházejí z časové řady let 2013 až 2018. V obrázku lze vidět, že oproti modelům za delší časové období se predikované hodnoty mnohem méně vychylují od reálné




hodnoty. V rámci těchto modelů nepřesahují absolutní odchylky hodnotu 17. mil Kč. Při srovnání s modely pro období v letech 2010 až 2018, lze také upozorovat, že v rámci období mezi únorem a červnem se hodnoty predikce více přibližují reálným hodnotám. Od června dále je rozdíl mezi hodnotami mnohem více výrazný.

Obr. 4.17: Absolutní odchylky predikovaných hodnot pro modely za období 2010-2018




Obr. 4.18: Absolutní odchylky predikovaných hodnot pro modely za období 2013-2018



V obrázku 4.19 jsou zachyceny hodnoty pro modely za období 2015 až 2018. Z obrázku je zřejmý už výše potvrzený fakt, že modely v rámci nejkratšího období jsou nejméně přesné, a že jedinými modely, které jsou do jisté míry použitelné pro predikci, je model interpolace pomocí inverzní funkce (černá křivka) a jednoduchý model průměru (modrá křivka).

Obr. 4.19: Absolutní odchylky predikovaných hodnot pro modely za období 2015-2018



Tab. 4.16: Ukazatele přesnosti modelů I. (mil. Kč)

	SSE	MSE	RMSE	MAE
INT8Y	37617,364	3761,736	61,333	62,132
INT5Y	711,466	71,147	8,435	7,471
INT3Y	6128,963	612,896	24,757	24,596
INT8Y(2)	307,310	30,731	5,544	4,771
INT5Y(2)	248,809	24,881	4,988	4,157
INT3Y(2)	335,434	33,543	5,792	5,078
Dmult8Y	3951,391	395,139	19,878	20,302
Dadit8Y	5706,425	570,642	23,888	22,715
Dmult8Y(2)	365,357	36,536	6,044	5,400
Dadit8Y(2)	34272,727	3427,273	58,543	57,161
Dmult5Y	329,966	32,997	5,744	5,038
Dadit5Y	381,587	38,159	6,177	5,469
LSE8Y	937,429	93,743	9,682	7,768
LSE5Y	673,331	67,333	8,206	7,023
LSE3Y	3039,651	303,965	17,435	16,332
LFL8Y	5875,462	587,546	24,239	24,692
LFL5Y	218,531	21,853	4,675	3,638
E(X)5Y	1282,962	128,296	11,327	10,897
E(X)3Y	543,298	54,330	7,371	6,147

V tabulce 4.16 jsou zaznamenány výsledky vybraných ukazatelů přesnosti. Barevná škála znázorňuje rozdíly v přesnosti mezi jednotlivými modely, přičemž tmavě zelená políčka značí nejpresnější modely a červená ty nejméně přesné. Z tabulky je tedy zřejmé, že mezi nejpresnější modely můžeme zařadit model stanovený v softwaru LFL Forecaster, který vychází z dat za období 2013-2017. Druhým nejpresnějším

modelem je pak model, ve kterém je hodnota predikce výsledkem lineární interpolace dat za období 2013-2017. Nejméně přesným je pak model, který vychází z interpolace kubickou funkcí pro časovou řadu 2010-2017.

Tab. 4.17: Ukazatele přesnosti modelů II.

	MAPE %	AMAPE %	Ustat	%předpovědi znaménka	% předpovědi směru
INT8Y	831,727	137,941	0,193	100,000	50,000
INT5Y	50,298	70,395	0,034	100,000	50,000
INT3Y	359,123	95,766	0,089	100,000	50,000
INT8Y(2)	57,297	42,903	0,022	100,000	50,000
INT5Y(2)	56,910	37,212	0,020	100,000	75,000
INT3Y(2)	56,838	45,949	0,023	100,000	50,000
Dmult8Y	197,096	492,458	0,080	0,000	62,500
Dadit8Y	176,680	2729,026	0,095	33,333	50,000
Dmult8Y(2)	66,927	48,236	0,024	100,000	62,500
Dadit8Y(2)	854,285	132,485	0,186	100,000	50,000
Dmult5Y	63,393	44,157	0,023	100,000	62,500
Dadit5Y	70,989	47,802	0,024	100,000	62,500
LSE8Y	153,676	48,251	0,037	100,000	50,000
LSE5Y	121,282	47,369	0,031	100,000	50,000
LSE3Y	198,724	78,247	0,064	100,000	50,000
LFL8Y	274,581	98,846	0,087	100,000	50,000
LFL5Y	72,088	31,648	0,018	100,000	75,000
E(X)5Y	168,965	62,733	0,046	100,000	50,000
E(X)3Y	115,938	43,634	0,030	100,000	75,000

Z tabulky 4.17 je zřejmé, že i když některé modely jsou na základě numerických metod velmi nepřesné, tak na základě stanovení směru vývoje nebo znaménka před hodnotou už jsou přesnější. Např. nejhorší model dle numerických metod, tedy model interpolace z časové řady 2010-2017 je, co se týče předpovědi znaménka, přesný ve všech měsících predikce, ale u předpovědi směru vývoje predikce je přesný jako většina ostatních modelů tedy z 50 %. Zvláštním případem je také model, který je kombinuje sezónní faktor a výsledek predikce lineární interpolace za období 2010-2017. V případě znaménka je model ze 100 % nepřesný, protože byly predikovány záporné hodnoty tržeb pro celé období, ale v případě směru je zase přesnější než většina ostatních modelů. Dalších zajímavých výsledků bylo dosaženo u modelu stanoveného v softwaru LFL Forecaster vycházejícího z dat za období 2013-2017. V tomto případě byl model dle numerických metod nejpřesnější avšak v případě předpovědi směru, patřil mezi ty nejméně přesné. Pro žádný z modelů není dosaženo dobrých výsledků jak v rámci numerických metod, tak v rámci předpovědi znaménka a

směru. Nelze tedy s jistotou tvrdit, který z daných modelů je nejlepší. Lze však tvrdit, že obecně mezi nejpřesnější můžeme zařadit modely, které vycházejí z kratší časové řady. Pokud bychom porovnali zvolené postupy, tak nelze z jistotou říct, který postup je pro predikci časových řad vybrané společnosti vhodný. Žádná z metod totiž není odolná vůči změnám délky vstupní časové řady, tedy že by v rámci dané metody příliš nezáleželo na tom, jestli vycházíme např. z dat za roky 2010 až 2017 nebo z dat za roky 2013 až 2017.

## 5 Závěr

Cílem této diplomové práce je nalézt modely vhodné pro predikci finančních časových řad vybraného podniku. Potřebná data byla čerpána z účetních databází společnosti a z veřejně dostupných zdrojů.

V druhé kapitole je popsána metodika predikce časových řad. Ve třetí kapitole jsou popsány jednotlivé metody pro stanovení přesnosti a vypovídací hodnoty jednotlivých modelů. V rámci čtvrté kapitoly jsou stanoveny hodnoty predikce dle jednotlivých metod a tyto výsledky jsou následně porovnány s reálnými hodnotami tržeb.

Na základě výsledků ze čtvrté kapitoly lze tvrdit, že vybranou časovou řadu nelze predikovat pomocí regresního modelu s vybranými vysvětlujícími veličinami. I když se může zdát, že by výše tržeb měla korelovat s vývojem indexu automobilového průmyslu, tržní cenou hliníku nebo s vývojem kurzu PLN/CZK, tak ve skutečnosti tomu tak není. Oproti tomu modely založené na dekompozici časové řady už jsou lépe použitelné a v některých případech jsou i poměrně přesné. Zkrácení časové řady z důvodu poměrně výrazného rozdílu mezi průměrnou výší tržeb v letech 2010 až 2012 a hodnotami zbytku období se v některých případech osvědčilo, např. v rámci predikce pomocí softwaru LFL Forecaster. Naopak u některých metod nemělo zkrácení časové řady téměř žádný vliv na výsledné hodnoty predikce. Např. u metody tzv. vyhlazování a hledání vhodné funkce se hodnota střední chyby odhadu pro všechny tři časové úseky pohybuje okolo 4. mil Kč. Na základě kritéria střední chyby odhadu tak můžeme tuto metodu zařadit mezi jednu z nejpřesnějších z hlediska odchylky predikované hodnoty od reálné výše tržeb. Je však dost možné, že takto dobrých výsledků bylo dosaženo jen díky náhodě, že se tržby v rámci horizontu predikce tržby zrovna pohybovaly okolo těchto hodnot. Vzhledem k jednoduchosti této metody, která nerespektuje žádnou ze systematických složek časové řady je tato skutečnost velmi pravděpodobná. Nicméně díky zkrácení časové řady na období od roku 2013 do 2018 se podařilo lépe odhadnout sezónní faktor časové řady nutný např. pro metodu exponenciálního vyrovnávání.

Obecně lze tvrdit, že modely vhodné pro predikce finančních časových řad vybraného podniku jsou modely, které vychází z dat za období mezi lety 2013 a 2018 a jsou založeny na dekompozici časové řady. Nejlepších hodnot pak bylo dosaženo v rámci predikce pomocí softwaru LFL Forecaster. Kdy střední chyba odhadu činila

3,64 mil. Kč a průměrná odhadovaná hodnota byla nejbližší průměru reálné výše tržeb v rámci horizontu predikce. Dále je nutné zmínit, že žádný z modelů není odolný vůči změnám v délce časové řady, tedy není možné jeden ze zvolených postupů použít pro libovolně dlouhou časovou řadu a přitom dosáhnout přibližně stejných výsledků.

## Seznam použité literatury

### Knižní publikace

ARLT, Josef a Markéta ARLTOVÁ. *Ekonomické časové řady*. Praha: Professional Publishing, 2009. ISBN 978-80-86946-85-6.

BREALEY, R. A., S. C. MYERS and F. ALLEN. *Principles of corporate finance*. 11th global ed. Maidenhead: McGraw-Hill Education, c2014. ISBN 978-0-07-715156-0.

CIPRA, Tomáš. *Finanční ekonometrie*. 2. upr. vyd. Praha: Ekopress, 2013. ISBN 978-80-86929-93-4.

GOURIEROUX, Christian a Joann JASIAK. *Financial econometrics: problems, models, and methods*. Princeton: Princeton University Press, c2001. Princeton series in finance. ISBN 0-691-08872-1.

HANČLOVÁ, Jana. *Ekonometrické modelování: klasické přístupy s aplikacemi*. Praha: Professional Publishing, 2012. ISBN 978-80-7431-088-1.

ZMEŠKAL, Z., D. DLUHOŠOVÁ a T. TICHÝ. *Finanční modely: koncepty, metody, aplikace*. 3., přeprac. a rozšíř. vyd. Praha: Ekopress, 2013. ISBN 978-80-86929-91-0

### Články v odborném periodiku

DVOŘÁČKOVÁ, H., A. KRESTA a T. TICHÝ. Sales Prediction in the Ice Category Applying Fuzzy Sets Theory. *Ekonomická Revue*. 2018, roč. 21, č.2. ISSN 1212-3951 <http://www.er-cerei.cz/archive/article?volume=21&issue=2&paper=341>

### Elektronické dokumenty a ostatní

Forecasting with seasonal adjustment and linear exponential smoothing. [online]. [cit. 2019-04-20]. Dostupné z: <http://people.duke.edu/~rnau/411outbd.htm>

PAVLISKA, Viktor. *Technika fuzzy modelování v algoritmickém a programovém zpracování*. Ostrava, 2009. Doktorská disertační práce. Ostravská univerzita v Ostravě, Fakulta přírodovědecká, Katedra matematiky. [http://irafm.osu.cz/f/PhD\\_theses/Pavliska.pdf](http://irafm.osu.cz/f/PhD_theses/Pavliska.pdf)

RAFM [online]. Copyright © [cit. 2019-04-20]. Dostupné z: [http://irafm.osu.cz/f/SW/LFLF\\_documentation.pdf](http://irafm.osu.cz/f/SW/LFLF_documentation.pdf)

## Seznam zkratek

CZK	česká Koruna
PLN	polský Złoty
INT8Y	Model dle interpolace kubickou funkcí za období 2010-2017
INT5Y	Model dle interpolace kubickou funkcí za období 2013-2017
INT3Y	Model dle interpolace kubickou funkcí za období 2015-2017
INT8Y(2)	Model dle interpolace exponenciální funkcí za období 2010-2017
INT5Y(2)	Model dle interpolace lineární funkcí za období 2013-2017
INT3Y(2)	Model dle interpolace inverzní funkcí za období 2015-2017
Dmult8Y	Model kombinace sezónního faktoru stanoveného multiplikativní vazbou a hodnoty predikované dle lineární interpolace za období 2010-2017
Dadit8Y	Model kombinace sezónního faktoru stanoveného aditivní vazbou a hodnoty predikované dle lineární interpolace za období 2010-2017
Dmult8Y(2)	Model kombinace sezónního faktoru stanoveného multiplikativní vazbou a hodnoty predikované dle exponenciální interpolace za období 2010-2017
Dadit8Y(2)	Model kombinace sezónního faktoru stanoveného aditivní vazbou a hodnoty predikované dle kubické interpolace za období 2010-2017
Dmult5Y	Model kombinace sezónního faktoru stanoveného multiplikativní vazbou a hodnoty predikované dle lineární interpolace za období 2013-2017
Dadit5Y	Model kombinace sezónního faktoru stanoveného aditivní vazbou a hodnoty predikované dle lineární interpolace za období 2013-2017
LSE8Y	Model exponenciálního vyrovnávání za období 2010-2017
LSE5Y	Model exponenciálního vyrovnávání za období 2013-2017
LSE3Y	Model exponenciálního vyrovnávání za období 2015-2017
LFL8Y	Model ze softwaru LFL Forecaster za období 2010-2017
LFL5Y	Model ze softwaru LFL Forecaster za období 2013-2017
E(X)5Y	Jednoduchý model průměru za období 2013-2017
E(X)3Y	Jednoduchý model průměru za období 2015-2017

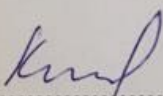


## Prohlášení o využití výsledků diplomové práce

Prohlašuji, že

- jsem byl seznámen s tím, že na mou diplomovou práci se plně vztahuje zákon č. 121/2000 Sb. – autorský zákon, zejména § 35 – užití díla v rámci občanských a náboženských obřadů, v rámci školních představení a užití díla školního a § 60 – školní dílo;
- beru na vědomí, že Vysoká škola báňská – Technická univerzita Ostrava (dále jen VŠB-TUO) má právo nevýdělečně, ke své vnitřní potřebě, diplomovou práci užít (§ 35 odst. 3);
- souhlasím s tím, že diplomová práce bude v elektronické podobě archivována v Ústřední knihovně VŠB-TUO. Souhlasím s tím, že bibliografické údaje o diplomové práci budou zveřejněny v informačním systému VŠB-TUO;
- bylo sjednáno, že s VŠB-TUO, v případě zájmu z její strany, uzavřu licenční smlouvu s oprávněním užít dílo v rozsahu § 12 odst. 4 autorského zákona;
- bylo sjednáno, že užít své dílo, diplomovou práci, nebo poskytnout licenci k jejímu využití mohu jen se souhlasem VŠB-TUO, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly VŠB-TUO na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Ostravě dne 26.04.2019 .....

  
.....  
Bc. Jan Kubečka

## **Seznam příloh**

Příloha č. 1 Tržby vybrané společnosti za období leden 2010 až říjen 2018 (v mil. Kč)

Příloha č. 2 Tržní cena hliníku za období leden 2010 až říjen 2018 (v USD za 1 tunu)

Příloha č. 3 Kurz PLN/CZK za období leden 2010 až říjen 2018

Příloha č. 4 Hodnoty indexu polského automobilového průmyslu za období leden 2010 až říjen 2018

Příloha č. 5 Hodnoty ukazatelů přesnosti při zahrnutí hodnot z lednu 2018 I. (v. mil Kč)

Příloha č. 6 Hodnoty ukazatelů přesnosti při zahrnutí hodnot z lednu 2018 II. (v. mil Kč)

## Přílohy

Příloha č. 1 Tržby vybrané společnosti za období leden 2010 až říjen 2018 (v mil. Kč)

<b>Tržby</b>	2010	2011	2012	2013	2014	2015	2016	2017	2018
leden	8,48	101,58	61,67	12,58	56,06	41,56	10,68	5,39	240,27
únor	48,23	141,86	137,23	16,71	38,27	42,19	22,25	20,14	11,94
březen	61,28	141,49	178,45	22,55	25,75	33,84	16,03	17,58	14,80
duben	90,68	99,60	114,51	22,18	22,02	26,05	18,40	16,23	12,33
květen	78,62	123,22	81,11	25,73	17,89	30,27	20,23	19,11	10,72
červen	55,16	102,61	93,98	25,54	23,83	39,64	15,73	16,54	14,10
červenec	72,60	116,38	114,44	36,61	24,83	24,11	6,57	11,52	18,22
srpen	46,09	87,96	91,15	39,32	27,34	21,71	10,67	22,83	19,97
září	83,30	159,79	92,80	39,65	35,54	31,07	12,91	30,63	16,87
říjen	102,73	190,70	151,14	41,52	42,79	11,60	11,48	20,46	2,31
listopad	119,05	130,02	189,22	43,44	47,94	7,22	10,36	17,75	0
prosinec	92,11	72,24	76,00	43,24	33,78	11,05	7,63	15,70	0

Příloha č. 2 Tržní cena hliníku za období leden 2010 až říjen 2018 (v USD za 1 tunu)

<b>Cena (Al)</b>	2010	2011	2012	2013	2014	2015	2016	2017	2018
leden	2230	2440	2151	2038	1727	1815	1481	1791	2210
únor	2053	2515	2208	2054	1695	1818	1531	1861	2182
březen	2211	2556	2184	1911	1705	1774	1531	1901	2069
duben	2314	2667	2049	1861	1811	1819	1571	1921	2255
květen	2045	2587	2003	1833	1751	1804	1551	1913	2300
červen	1929	2558	1886	1815	1839	1688	1594	1885	2238
červenec	1989	2525	1876	1770	1948	1640	1629	1903	2082
srpen	2110	2381	1843	1816	2030	1548	1639	2030	2052
září	2171	2293	2064	1761	1990	1590	1592	2096	2026
říjen	2342	2181	1974	1815	1946	1516	1666	2131	2030
listopad	2324	2080	1949	1748	2056	1468	1737	2097	0
prosinec	2357	2024	2087	1740	1909	1497	1728	2080	0

Zdroj:

<https://www.indexmundi.com/commodities/?commodity=aluminum&months=300>

Příloha č. 3 Kurz PLN/CZK za období leden 2010 až říjen 2018

<b>PLN/CZK</b>	2010	2011	2012	2013	2014	2015	2016	2017	2018
leden	6,422	6,285	5,834	6,175	6,582	6,528	6,146	6,189	6,114
únor	6,462	6,183	5,982	6,106	6,570	6,611	6,147	6,269	6,077
březen	6,563	6,076	5,971	6,174	6,524	6,634	6,304	6,341	6,041
duben	6,536	6,121	5,935	6,243	6,563	6,814	6,274	6,325	6,053
květen	6,333	6,182	5,903	6,203	6,565	6,722	6,134	6,324	5,983
červen	6,285	6,122	5,961	6,011	6,639	6,569	6,152	6,236	5,991
červenec	6,205	6,102	6,083	6,071	6,625	6,520	6,151	6,157	5,977
srpen	6,220	5,887	6,121	6,101	6,631	6,195	6,282	6,119	5,995
září	6,244	5,683	5,997	6,082	6,584	6,424	6,248	6,107	5,960
říjen	6,211	5,692	6,074	6,127	6,556	6,382	6,272	6,043	5,999
listopad	6,233	5,752	6,136	6,408	6,575	6,360	6,147	6,044	0
prosinec	6,303	5,694	6,149	6,589	6,537	6,297	6,097	6,108	0

Zdroj: <https://www.ofx.com/en-au/forex-news/historical-exchange-rates/>

Příloha č. 4 Hodnoty indexu polského automobilového průmyslu za období leden 2010 až říjen 2018

<i>Index</i>	2010	2011	2012	2013	2014	2015	2016	2017	2018
leden	69,8	86,9	88,1	80,1	85,5	99,5	106,1	115,3	114,4
únor	71,0	87,4	88,2	83,0	87,0	98,9	109,9	115,1	113,9
březen	75,7	86,2	79,6	81,8	88,3	101,3	104,2	115,4	118,9
duben	71,3	87,1	82,2	86,1	89,1	98,2	106,0	115,2	117,5
květen	76,9	87,3	80,1	86,1	90,7	95,4	107,4	114,5	121,2
červen	81,5	84,1	80,3	85,8	91,4	96,9	108,4	112,7	122,9
červenec	76,8	86,5	84,5	87,8	99,0	107,8	101,4	108,5	113,0
srpen	71,0	86,1	78,2	92,3	76,9	95,5	108,9	122,5	125,3
září	78,1	87,0	80,8	91,0	93,2	98,8	107,2	114,7	120,3
říjen	77,7	88,4	80,1	87,2	91,4	98,6	109,7	117,0	123,9
listopad	76,8	87,9	77,8	90,7	93,8	105,2	106,5	121,1	0
prosinec	79,4	88,5	75,4	84,7	95,5	103,7	113,2	120,7	0

Zdroj: <https://ec.europa.eu/eurostat/data/database>

Příloha č. 5 Hodnoty ukazatelů přesnosti při zahrnutí hodnot z lednu 2018 I. (v. mil Kč)

	SSE	MSE	RMSE	MAE
INT8Y	75160,668	7516,067	86,695	75,295
INT5Y	53804,144	5380,414	73,351	29,766
INT3Y	51907,945	5190,795	72,047	43,532
INT8Y(2)	52624,519	5262,452	72,543	27,167
INT5Y(2)	51742,655	5174,265	71,932	26,434
INT3Y(2)	52755,164	5275,516	72,633	27,465
Dmult8Y	62115,110	6211,511	78,813	42,389
Dadit8Y	71823,061	7182,306	84,748	46,157
Dmult8Y(2)	53907,409	5390,741	73,422	27,999
Dadit8Y(2)	79060,642	7906,064	88,916	72,608
Dmult5Y	52442,435	5244,243	72,417	27,362
Dadit5Y	50526,928	5052,693	71,082	27,315
LSE8Y	51651,707	5165,171	71,869	29,511
LSE5Y	50305,889	5030,589	70,927	28,599
LSE3Y	53918,699	5391,870	73,429	37,255
LFL8Y	51603,040	5160,304	71,835	43,606
LFL5Y	51253,892	5125,389	71,592	25,865

Příloha č. 6 Hodnoty ukazatelů přesnosti při zahrnutí hodnot z lednu 2018 II.

	MAPE %	AMAPE %	Ustat	%předpovědí	%kroků
INT8Y	114,774	137,660	0,275	100,000	55,556
INT5Y	360,373	81,780	0,297	100,000	55,556
INT3Y	138,378	102,242	0,259	100,000	55,556
INT8Y(2)	241,648	56,779	0,289	100,000	55,556
INT5Y(2)	204,381	51,386	0,285	100,000	77,778
INT3Y(2)	250,933	59,555	0,290	100,000	55,556
Dmult8Y	2990,830	463,362	0,319	0,000	55,556
Dadit8Y	442,128	2479,142	0,335	30,000	55,556
Dmult8Y(2)	310,733	61,987	0,293	100,000	66,667
Dadit8Y(2)	145,170	134,976	0,286	100,000	55,556
Dmult5Y	233,875	57,840	0,287	100,000	66,667
Dadit5Y	185,153	60,475	0,281	100,000	66,667
LSE8Y	180,318	61,065	0,275	100,000	55,556
LSE5Y	158,204	59,918	0,273	100,000	55,556
LSE3Y	200,953	88,115	0,273	100,000	55,556
LFL8Y	139,089	104,997	0,258	100,000	55,556
LFL5Y	180,501	46,227	0,281	100,000	77,778